

# Sistemas Informáticos



## UNIVERSIDAD COMPLUTENSE MADRID

Curso 2015 – 2016

Identificación de imágenes por análisis de  
texturas utilizando aprendizaje estadístico

Realizado por:

**JAVIER ESCOBAR RIOSALIDO**

Dirigido por:

**JOSÉ JAIME RUZ ORTIZ**



**AUTORIZACIÓN PARA LA DIFUSIÓN DEL TRABAJO FIN DE GRADO Y SU DEPÓSITO EN EL REPOSITORIO INSTITUCIONAL E-PRINTS COMPLUTENSE**

Los abajo firmantes, alumno/s y tutor/es del Trabajo Fin de Grado (TFG) en el Grado en

.....de la Facultad de

....., autorizan a la Universidad Complutense de Madrid (UCM) a difundir y utilizar con fines académicos, no comerciales y mencionando expresamente a su autor el Trabajo Fin de Grado (TF) cuyos datos se detallan a continuación. Así mismo autorizan a la Universidad Complutense de Madrid a que sea depositado en acceso abierto en el repositorio institucional con el objeto de incrementar la difusión, uso e impacto del TFG en Internet y garantizar su preservación y acceso a largo plazo.

Periodo de embargo (opcional):

☐ 6 meses

☐ 12meses

TÍTULO del TFG: .....

.....

Curso académico: 20..... / 20.....

Nombre del Alumno/s:

.....

.....

Tutor/es del TFG y departamento al que pertenece:

.....

.....

.....

Firma del alumno/s

Firma del tutor/es



## AGRADECIMIENTOS:

1. En primer lugar quiero agradecer a toda mi familia por el empeño y la paciencia que han tenido conmigo a lo largo de todo el desarrollo del proyecto.
  - A mi **padre** por enseñarme los frutos que da un trabajo duro y siempre recordarme que aunque el trabajo realizado esté bien, siempre se puede hacer mejor y hacerme ver que sabiendo más acerca de un tema destacas sobre todos los demás.
  - A mi **madre** por la paciencia y la confianza depositada en mí apoyándome en los momentos donde el estrés y el cansancio hacían mella, sacando la mejor de sus sonrisas cuando más lo necesitaba.
  - A mi **hermana** por su incondicional sentido del humor al mostrarme que aunque las cosas no vayan bien, siempre hay momentos para reírse y para darse cuenta que a veces los momentos más absurdos son los momentos de más lucidez.
  - Y por último a toda mi familia por entender mis ausencias en actos importantes por el motivo de realizar este trabajo de investigación.
2. En segundo lugar quiero agradecer al organismo de la Universidad Complutense de Madrid por brindarme la oportunidad y los medios necesarios para realizar este trabajo de investigación:
  - A mi profesor y tutor del trabajo de fin de grado **José Jaime Ruz Ortiz** por enseñarme y dirigirme tan bien a lo largo del proyecto aclarándome las dudas surgidas en el desarrollo del mismo, pudiendo así completar el trabajo y darme la oportunidad de introducirme en el mundo de la inteligencia artificial.
  - Al personal de la facultad de informática de la Universidad Complutense de Madrid al facilitarme su ayuda, ya sea personal de la cafetería, personal administrativo y personal de la biblioteca.
3. En tercer y último lugar quiero hacer una mención especial al **HOSPITAL CLÍNICO SAN CARLOS**, por facilitarme las imágenes y por su solidaridad al haber sacado el tiempo para atenderme, explicarme las posibles patologías por las que podría haber orientado el trabajo y sobre todo por haber hecho el grandísimo trabajo de procesar dichas imágenes para que, de acuerdo con la *“La Ley Orgánica 15/1999, de 13 de diciembre, de Protección de Datos de Carácter Personal (LOPD)”*, pudieran ser anonimizadas para su posterior tratamiento y publicación en este trabajo de investigación. En especial mención a:
  - **Victoria Botyanovskaya** por ponerme en contacto con el personal pertinente del hospital, dándome la oportunidad de empaparme más en el mundo de la bioinformática.
  - **Ana M Crespo Rodríguez**, doctora en el hospital Clínico San Carlos y experta en radiología con publicaciones asombrosas en el área del diagnóstico por imagen: [https://www.researchgate.net/profile/Ana\\_Crespo\\_Rodriguez/info](https://www.researchgate.net/profile/Ana_Crespo_Rodriguez/info). Por su paciencia al atenderme y por ponerse en mi piel a la hora de simplificar el problema de la discriminación en imágenes tan complejas.



## 1. INTRODUCCIÓN:

- a. RESUMEN DEL PROYECTO.
  - i. RESUMEN.
  - ii. PALABRAS CLAVE.
  - iii. ABSTRACT.
  - iv. KEY WORDS.
- b. OBJETIVOS.
- c. JUSTIFICACIÓN DEL PROYECTO.
  - i. TÉCNICAS DE APRENDIZAJE AUTOMÁTICO.
  - ii. CLASIFICACIÓN EN BASE AL APRENDIZAJE SUPERVISADO.
- d. DESCRIPCIÓN DEL “QUISTE DE BAKER”.
- e. PRINCIPIOS FÍSICOS DE LA IMAGEN POR RESONANCIA MAGNÉTICA NUCLEAR.

## 2. PLANIFICACIÓN

- a. ORGANIZACIÓN.
- b. PLAN DE FASE.
  - i. FASE DE INICIO.
  - ii. FASE DE ELABORACIÓN.
  - iii. FASE DE CONSTRUCCIÓN
  - iv. FASE DE TRANSICIÓN.

## 3. ANÁLISIS

- a. ESPECIFICACIÓN DEL PROYECTO.
  - i. PROCESAMIENTO DE IMÁGENES.
  - ii. DISEÑO DE LA MATRIZ DE CO-OCURRENCIA.
  - iii. ASPECTOS A RESALTAR DE LA MATRIZ DE CO-OCURRENCIA.
  - iv. MEDIDAS TEXTURALES UTILIZADAS PARA EL ANÁLISIS.
  - v. DATOS ESTADÍSTICOS COMPLEMENTARIOS.
  - vi. MÁQUINAS DE VECTORES SOPORTE.
  - vii. CLASIFICACIÓN LINEAL SEPARABLE.
  - viii. CLASIFICACIÓN LINEAL NO SEPARABLE.
  - ix. TEORÍA DE LA GENERALIZACIÓN.
  - x. VENTAJAS DE LAS MÁQUINAS DE VECTORES SOPORTE.
  - xi. PROBLEMAS COMUNES CON MÁQUINAS DE VECTORES SOPORTE.

## 4. DISEÑO

- a. ESPECIFICACIÓN DEL DISEÑO.
  - i. DIAGRAMAS DE CASOS DE USO.
  - ii. DIAGRAMAS DE CLASE GENERAL.
  - iii. DIAGRAMAS DE SECUENCIA.
    - 1. CARGAR IMAGEN.

2. TERMINAR PROCESOS.
3. VER VECTORES.
4. ABRIR VENTANA SVM.
5. PROCESO.
6. EMPEZAR MUESTREO.
7. CLASIFICAR.
8. CARGAR ARCHIVO PARA MODELO.
9. CARGAR MODELO.
10. APRENDIZAJE.

b. RIESGOS.

- i. TECNOLÓGICOS.
- ii. CONOCIMIENTO.
- iii. DISPONIBILIDAD DE REUNIÓN.

5. **RESULTADOS DEL PROYECTO**

- a. INTRODUCCIÓN.
- b. RESULTADOS ESTADÍSTICOS.
- c. CONCLUSIÓN.
- d. CONCLUSION.

6. **BIBLIOGRAFIA**

7. **ANEXO Y RESULTADOS DE LAS PRUEBAS**

- a. MANUAL DE USUARIO ANÁLISIS DE IMAGEN.
- b. MANUAL DE USUARIO APRENDIZAJE AUTOMÁTICO.
- c. FUTUROS DESARROLLOS.



# CAPITULO 1. INTRODUCCIÓN

## 1. INTRODUCCIÓN

### 1.1 RESUMEN DEL PROYECTO

#### 1.1.1 RESUMEN

Este documento explica la creación, implementación y uso del proyecto de fin de grado, desarrollado dentro del grupo de investigación ISCAR (Ingeniería de Sistemas, Control, Automática y Robótica) de la Facultad de Informática de la Universidad Complutense.

El proyecto consiste en la implementación de una aplicación capaz de clasificar texturas extraídas de distintas imágenes mediante técnicas de visión por computador. Dicha aplicación se divide en tres pilares fundamentales: interfaz gráfica de usuario, algoritmos de extracción de características texturales y aprendizaje supervisado mediante una máquina “SVM” (Support Vector Machine).

*Interfaz gráfica:* proporciona al usuario una forma fácil de uso de la aplicación por medio de la visualización gráfica de una imagen con una serie de elementos de configuración para su posterior análisis. Una vez analizada, el usuario si así lo desea, podrá visualizar los resultados de manera intuitiva, así como guardar dichos resultados después de la ejecución de los algoritmos pertinentes.

*Algoritmos de análisis de texturas:* Procede al cálculo de las configuraciones y las muestras provistas por el usuario en la interfaz gráfica como el cálculo de la matriz de co-ocurrencia y el cálculo de los vectores de características (homogeneidad, media, varianza, Entropía, etc...).

*SVM:* Utiliza los vectores de características obtenidos en los cálculos estadísticos de texturas para realizar el proceso de aprendizaje de un clasificador SVM.

La aplicación ha sido construida en JAVA haciendo uso de librerías como JNI\_SVM-light-6.01, commons-math3-3.0 y WindowsBuilder, para la construcción de la ventana gráfica, cálculo de los métodos estadísticos y máquina de aprendizaje automático.

Dicha aplicación se ha utilizado con el objetivo de identificar y clasificar el quiste de Baker mediante imágenes obtenidas por Resonancias Magnéticas de la rodilla.

#### 1.1.2 PALABRAS CLAVE

SVM (Support Vector Machine), matriz de co-ocurrencia, aprendizaje vectorial, escala de grises, mapa de bits, clasificación RGB, vector de características, metodología de segundo orden.

#### **1.1.4 ABSTRACT**

This document explains the creation, implementation and use of project to degree, developed within the research group SECAR (Systems Engineering, Control, Automation and Robotics) at the school of Computer Science at the Complutense University.

The project involves the implementation of an application capable of classify textures taken from different viewing images using techniques computer.

Such application is divided into three pillars: graphical user interface, extraction algorithms textural characteristics and supervised learning by "SVM" (Support Vector Machine).

*GUI:* it provides the user an easy way to use the application through the graphical display of an image with a number of elements who can customize for further analysis. Once analyzed, if the user so wish can view the results intuitively and save these results after the execution of the relevant algorithms.

*Texture analysis algorithms:* It comes to calculate the configurations and the samples provided by the user in the GUI as the calculation the co-occurrence matrix and the calculation the characteristics vectors (homogeneity, mean, variance, entropy, etc....).

*SVM:* It uses the feature vectors obtained in statistical calculations of textures to do the learning process of a SVM classifier.

The application has been built in JAVA using libraries as JNI\_SVM-light-6.01, commons-math3-3.0 and WindowsBuilder, for the construction of the GUI, calculation the statistical methods and finally, the machine learning.

Such application has been used to identify and classify cyst Baker's using images obtained by magnetic resonance imaging of the knee.

#### **1.1.4 KEY WORDS**

SVM (Support Vector Machine), co-occurrence matrix, vector learning, grayscale, bitmap, RGB classification, feature vector, second order classification methodology.

## 1.2 OBJETIVOS

Los objetivos a conseguir con el desarrollo de la aplicación propuesta que se recogen en la presente memoria son los siguientes:

➤ **Objetivo final:**

- Identificación y clasificación del quiste de Baker en imágenes obtenidas por resonancia magnética de la rodilla.

➤ **Objetivos generales:**

- Uso del análisis textural de las imágenes como técnica de visión artificial.
- Comunicación entre el usuario y el programa mediante una interfaz gráfica intuitiva.
- Uso de parámetros de segundo orden de la matriz de co-ocurrencia como alternativa dentro del análisis textural.
- Uso de una Máquina de Vectores de Soporte (SVM) como alternativa de aprendizaje para la clasificación en base a vectores de características obtenidas en imágenes.
- Identificación de valores estadísticos útiles para el análisis textural.
- Implementación de los métodos correspondientes a los procedimientos previamente descritos.
- Garantizar el correcto funcionamiento de la aplicación.
- Realización de la documentación pertinente descrita en esta memoria.

## 1.3 JUSTIFICACIÓN DEL PROYECTO

### 1.3.1 TÉCNICAS DE APRENDIZAJE AUTOMÁTICO

Las técnicas de aprendizaje automático tienen como objetivo conseguir diferenciar automáticamente patrones usando algoritmos matemáticos. Dichas técnicas son comúnmente utilizadas para clasificar imágenes. Entre estas técnicas se pueden distinguir dos tipos:

- **Aprendizaje supervisado:** El algoritmo produce una función que establece una correspondencia entre las entradas y salidas deseadas del sistema. Un ejemplo de este tipo de algoritmo es el problema de clasificación, donde el sistema de aprendizaje trata de etiquetar una serie de vectores utilizando una entre varias categorías. La base de conocimiento del sistema está formada por ejemplos etiquetados anteriormente en un muestreo previo de la imagen. Este tipo de aprendizaje es el que se ha utilizado

para el proyecto, ya que es muy eficiente en problemas de investigación biológica, biología computacional y bioinformática.

- **Aprendizaje no supervisado:** En este tipo de aprendizaje, la salida representa el grado de similitud entre los datos que se le están presentando en la entrada y los datos que se le han mostrado hasta entonces. Al no tener información sobre la categoría de dichos datos, el sistema tiene que ser capaz de reconocer patrones para poder etiquetar nuevas entradas.

Entre las técnicas de aprendizaje, el aprendizaje no supervisado tiene un comportamiento muy bueno en el análisis de los patrones texturales de las imágenes, ya que permite la identificación de la presencia en las mismas de determinadas zonas significativas. Las técnicas de análisis pueden ser muy diversas pero las basadas en procesos de clasificación que caracterizan las muestras de la imagen con parámetros estadísticos de primer y segundo orden presentan un buen compromiso entre tiempo de cómputo y calidad de la solución.

### 1.3.2 CLASIFICACIÓN EN BASE AL APRENDIZAJE SUPERVISADO

Los clasificadores más utilizados son las redes neuronales, las máquinas de vectores soporte, el algoritmo de los K-vecinos más cercanos, el clasificador bayesiano ingenuo, los árboles de decisión y las funciones de base radial.

A diferencia de las Redes Neuronales Artificiales (RNA), que utilizan durante la fase de entrenamiento el principio de Minimización del Riesgo Empírico (ERM), las SVM se basan en el principio de Minimización del Riesgo Estructural (SRM). El principio SRM ha mostrado un mejor comportamiento que el ERM. Las Máquinas de Vectores Soporte minimizan un límite superior del riesgo esperado a diferencia del ERM que minimiza el error sobre los datos de entrenamiento.

Las SVM mapean los puntos de entrada a un espacio de características de una dimensión mayor, para luego encontrar el hiperplano que los separe y maximice el margen entre las clases.

Pertenecen a la familia de clasificadores lineales puesto que inducen separadores lineales o hiperplanos en espacios de características de muy alta dimensionalidad (introducidos por funciones núcleo o Kernel) con un sesgo inductivo muy particular.

En conclusión, las Máquinas de Vectores Soporte (SVM) constituyen un método de aprendizaje supervisado para problemas de clasificación que se complementa bien con el análisis estadístico de texturas. En este proyecto se plantea el diseño de un entorno de desarrollo que facilite la

obtención de clasificadores basados en el análisis textural de imágenes utilizando SVM para detectar la presencia de un determinado tipo de lesión en el escenario de la imagen.

#### 1.4 DESCRIPCIÓN DEL QUISTE DE BAKER

El “*Quiste de Baker*” o “*Quiste poplíteo*”, es una acumulación de líquido articular (líquido sinovial), procedente de la cápsula articular. Este líquido sinovial se acumula en la “*Bursa*” o bolsa del “*gastrocnemio-semimembranosa*” que se comunica con la articulación de la rodilla por una abertura en la superficie posterior y medial de la capsula articular y mediante mecanismos valvulares se facilita su llenado, no así su vaciamiento (Este mecanismo es el que facilita la función de bisagra en la rodilla). Su acumulación se produce al debilitarse la membrana sinovial que reduce la articulación, formando un quiste poplíteo detrás de la rodilla, en el llamado hueco poplíteo (comúnmente llamado “**corva**”). Cuando la presión se acumula, el líquido protruye hacia la parte posterior de la rodilla y puede llegar a ocasionar serias molestias.

Cuando hay un problema en la articulación, la cápsula articular reacciona produciendo mayor cantidad de líquido sinovial, proceso que se conoce como derrame articular. El exceso de líquido se acumula en la región posterior de la rodilla, ocasionando este “**quiste de Baker**”, el cual puede aparecer a cualquier edad, incluyendo etapas tempranas de la vida.

Algunas de las causas en pacientes mayores de la producción excesiva de líquido sinovial y en consecuencia de la aparición de éste quiste son:

- **Artrosis.**
- **Artritis reumatoide.**

En adultos jóvenes son producidos, en la mayoría de los casos, por traumatismos que conllevan lesiones características como:

- **Lesión en los ligamentos de la rodilla.**
- **Rotura de menisco.**
- **Desgaste del cartílago articular.**

Cuando existe un quiste grande (Figura 1), éste puede llegar a causar molestia o rigidez, dificultar para flexionar la rodilla, o bien comprimir venas o nervios, originando sintomatología más intensa, pudiendo sentirse como un globo lleno de agua o una ocupación de espacio en la parte posterior de la rodilla:



Figura 1

Algunas veces, el quiste se puede romper y causar dolor, inflamación y hematoma en la parte posterior de la rodilla y la pantorrilla. Es muy importante saber si el dolor o el hinchazón es causado por un quiste de Baker o por un coágulo de sangre, ya que un coágulo sanguíneo o trombosis venosa profunda podría presentar una similitud clínica. Esto hay que tenerlo muy presente ya que puede llevar a un diagnóstico erróneo.

Generalmente en la mayoría de los casos el tratamiento es médico, lo que incluye la reducción de la producción de líquido tratando la enfermedad articular de base, el reposo con la pierna elevada y compresión suave; esto último especialmente cuando el quiste está roto.

El tratamiento quirúrgico raras veces necesario, y puede consistir simplemente en la aspiración del contenido del quiste si produce mucho dolor y efectos compresivos por gran distensión. Otra opción es realizar una artroscopia tratando el quiste o incluso extrayéndolo por cirugía convencional.

## 1.5 PRINCIPIOS FÍSICOS DE LA IMAGEN POR RESONANCIA MAGNÉTICA NUCLEAR.

- El magnetismo y la excitación.

El fenómeno del **magnetismo** tiene su origen en el movimiento de las partículas cargadas eléctricamente. La magnetización se refiere al fenómeno causado por una orientación no aleatoria del campo magnético de los electrones. Esta orientación da lugar a una magnetización macroscópica neta. Además de los electrones, la mayoría de los núcleos atómicos también posee un pequeño campo o momento magnético, que es el que se utiliza en la obtención de imágenes por RM (resonancia magnética). Este magnetismo nuclear tiene su origen en el spin nuclear y el valor del momento angular asociado a él, y se encuentra directamente relacionado tanto con el número atómico (número de protones) como con el número másico (número de protones más números de neutrones) o con el número de neutrones. Existen dos situaciones en las que se origina un momento magnético nuclear neto:

1. Cuando el número de protones y el número másico son impares (o el número de neutrones es par), como en el  $^1\text{H}$  (Hidrógeno),  $^{15}\text{N}$  (Nitrógeno),  $^{19}\text{F}$  (Flúor),  $^{23}\text{Na}$  (Sodio) y  $^{31}\text{P}$  (Fósforo).
2. Cuando el número de protones es par y el de neutrones es impar (o número másico impar) como el  $^{13}\text{C}$  (Carbono).

El hidrógeno, con un protón ( $^1\text{H}$ ) como núcleo más simple de todos los elementos, es un buen isótopo para la obtención de imágenes al ser el núcleo más abundante en el cuerpo y poseer un momento magnético muy grande. Normalmente estos spins o momentos magnéticos están alineados de forma aleatoria, de manera que no sometido a ningún campo magnético externo, no existe magnetización neta, tal y como se puede observar en la Figura 2.a:




Figura 2.a




Figura 2.b

Cuando el material se sitúa en el interior de un campo magnético, estos momentos magnéticos se alinean con dicho campo magnético (misma dirección) existiendo una mayor cantidad de spines que se orientaran en el mismo sentido que el campo magnético principal en comparación con los que lo harán en sentido contrario (Figura 2.b).

Esto dará como resultado un momento magnético neto que se situará en equilibrio. Este momento magnético neto, también llamado magnetización neta, es la base para la creación de la señal RM.

Tal y como se ha comentado, los átomos con un número impar de protones o neutrones poseen un momento angular o spin. En ausencia de un campo magnético externo, los espines estarán orientados aleatoriamente, pero cuando se sitúan bajo un campo magnético intenso, los espines se alinean con este, proporcionando una magnetización longitudinal neta,  $M_z$ , en la dirección del campo aplicado (supongamos  $z$ ). Estos spines procesan alrededor del eje  $z$  a una frecuencia directamente proporcional a la intensidad del campo magnético, tal y como puede observarse en la Figura 3:






Figura 3

La ecuación de Larmor describe la dependencia entre el campo magnético  $B_0$  y la frecuencia angular a la que están procesando dichos spines.

- *Ecuación de Larmor*

$$\omega_0 = \gamma |B_0|$$

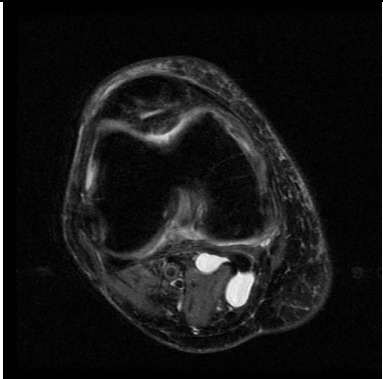
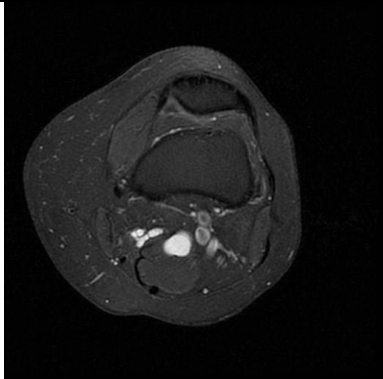
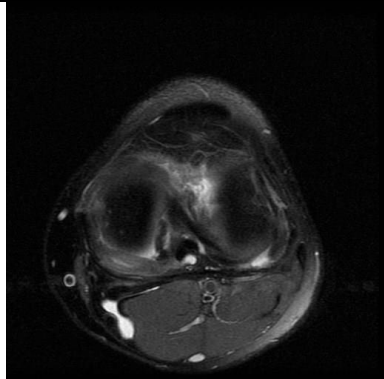
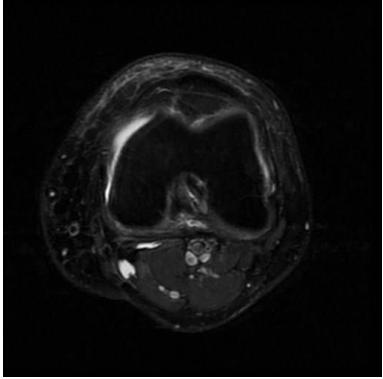
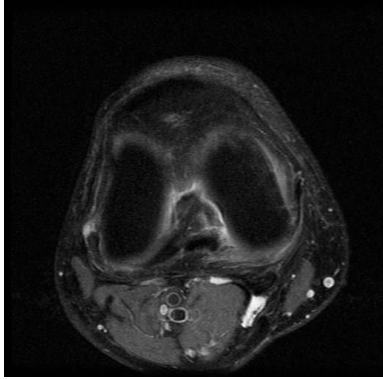
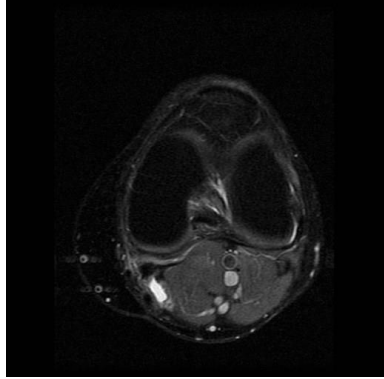
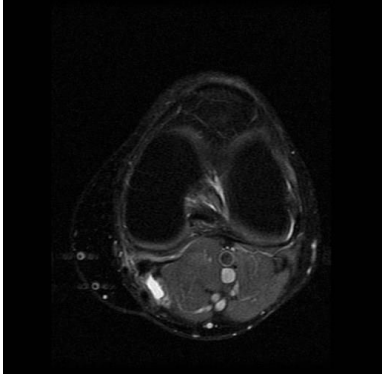
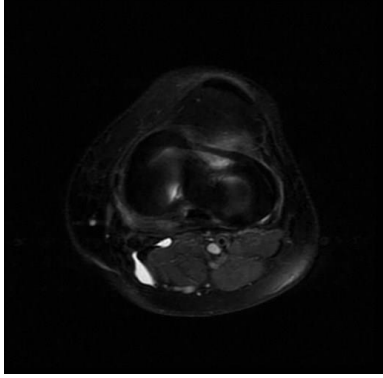
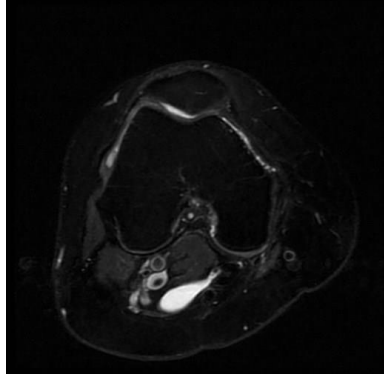
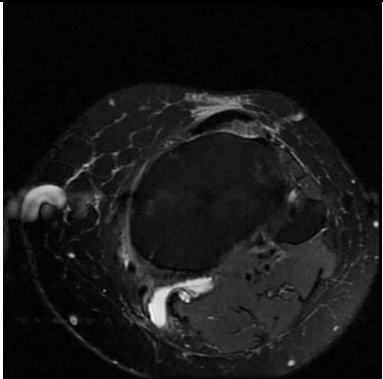
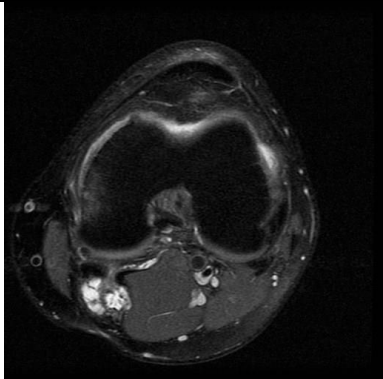
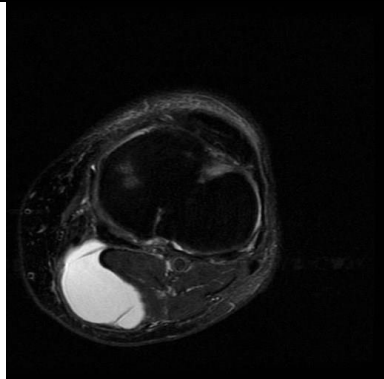
La constante giromagnética  $\gamma$  depende del átomo bajo estudio, y tiene un valor de 42.58 MHz/T para el  $^1\text{H}$ . Los protones de hidrogeno son los que usualmente se utilizan en prácticas clínicas debido a su gran abundancia en el tejido vivo (60 % de H procedente del agua).

- **Gradiente de campo magnético: codificación espacial:**

Los gradientes de campo magnético son elementos de un sistema de resonancia magnética que permiten resolver la posición espacial, y por lo tanto, reconstruir una imagen. Tres gradientes de campo magnético proporcionan una variación lineal en la intensidad del campo magnético longitudinal como función de la posición a lo largo de las tres direcciones ortogonales, normalmente a lo largo del núcleo del imán, horizontalmente a través del núcleo, y verticalmente a través del núcleo. La determinación de la localización espacial de una señal de resonancia magnética nuclear depende de la secuencia de aplicación de los tres gradientes de campo magnético ( $G_x$ ,  $G_y$  y  $G_z$ ).

- **Construcción de la imagen y resultado de la RM:**

A continuación se mostrarán doce imágenes extraídas por resonancia magnética del hospital clínico San Carlos, las cuales han servido para el análisis, aprendizaje y clasificación correspondiente al experimento del proyecto:

		
Resonancia Magnética 1	Resonancia Magnética 2	Resonancia Magnética 3
		
Resonancia Magnética 4	Resonancia Magnética 5	Resonancia Magnética 6
		
Resonancia Magnética 7	Resonancia Magnética 8	Resonancia Magnética 9
		
Resonancia Magnética 10	Resonancia Magnética 11	Resonancia Magnética 12

## **CAPITULO 2. PLANIFICACIÓN**

### **2 PLANIFICACIÓN**

A continuación se explicará la planificación del proyecto, dividiendo el mismo en distintas fases y explicando el tiempo necesitado para cada hito y el procedimiento empleado.

Este proyecto ha sido realizado en ocho meses por una única persona, Javier Escobar Riosalido, lo que supone un tiempo bastante amplio dedicado para cada tarea en un proyecto, aunque no ha sido continuo por motivos laborales y de carácter universitario, al compaginarlo con otras asignaturas.

#### **2.1 ORGANIZACIÓN**

El proyecto consiste en una aplicación que se puede dividir en tres partes: interfaz gráfica de análisis de texturas, procedimientos de análisis de texturas e interfaz gráfica de un clasificador SVM.

Dado que el proyecto está realizado por una persona, no ha sido necesario establecer pautas de grupo, organización de integrantes, ni jerarquías de personal para la realización del trabajo.

Las tres partes del proyecto han sido desarrolladas en paralelo, ya que era más sencillo hacer las comprobaciones pertinentes antes de continuar desarrollando.

#### **2.2 PLAN DE FASE**

##### **2.2.1 FASE DE INICIO**

Fecha de inicio: 13 de Octubre de 2015

Fecha fin: 18 de Noviembre de 2015

Objetivos:

- Reunión con el tutor con el fin de definir el alcance y los objetivos del proyecto.
- Estudio teórico de dichos requisitos ya que no fueron vistos en otras asignaturas.

- Búsqueda de documentación y estudio de procedimientos como: “Matriz de co-ocurrencia”, “Análisis de texturas mediante píxeles”, uso de máquinas vectoriales así como estudio de sus distintas funcionalidades, organización de clases y modelo empleado.
- Elección del lenguaje utilizado para el desarrollo de la aplicación. Para este proyecto se ha decidido usar JAVA por su sencillez en el manejo de este lenguaje, pero ya que se hacen cálculos estadísticos, quizás hubiera sido mejor MATLAB o C++ por su rapidez tanto en el cálculo como en el tratamiento de imágenes respectivamente.
- Familiarización de la librería commons-math3-3.0 para los cálculos estadísticos.
- Familiarización de la biblioteca JNI\_SVM-light-6.01 para el aprendizaje automático.
- Organización del plan de fase.

### **2.2.2 FASE DE ELABORACIÓN**

Fecha de inicio: 23 de Noviembre de 2015

Fecha fin: 11 de Diciembre de 2015

Objetivos:

- Especificación de la arquitectura empleada en el proyecto dividiendo sus funcionalidades lo máximo posible para su completa atomicidad.
- Desarrollo de diagramas UML (Unified Modeling Language) para los casos de uso, clase, actividad y secuencia.
- Diseño de interfaz gráfica para cada una de las funcionalidades.
- Diseño de formato para lectura y escritura del archivo de resultados para su posterior aprendizaje.
- Creación de clases del modelo y creación de controladores para la visualización de los cambios en la vista.
- Búsqueda de imágenes médicas para posterior análisis.

### **2.2.3 FASE DE CONSTRUCCIÓN**

La fase de construcción queda dividida en cinco iteraciones.

#### **- ITERACIÓN 1**

Fecha de inicio: 1 de Enero de 2016

Fecha fin: 14 de Enero de 2016

- Revisión de especificaciones y requisitos.

- Implementación de ventana gráfica de análisis de texturas.
- Implementación de métodos encargados del formato de los archivos externos a utilizar.
- Revisión de dichos procedimientos.
- Creación del primer prototipo de la aplicación.
- Documentación de esta fase.

#### - ITERACIÓN 2

Fecha de inicio: 15 de Enero de 2016

Fecha fin: 9 de Febrero de 2016

- Implementación de procedimientos para el análisis de imágenes.
- Definición de cálculos estadísticos necesarios para dicho análisis.
- Desarrollos de pruebas en ventana gráfica para comprobar el correcto funcionamiento.
- Creación de métodos estadísticos en el modelo de la aplicación.
- Creación de métodos para la salida obtenida por medio de archivos “.dat” para su posterior análisis en la máquina de vectores soporte.
- Pruebas de cálculos y desarrollo de métodos de prueba.
- Documentación de esta fase.

#### - ITERACIÓN 3

Fecha de inicio: 10 de Febrero de 2016

Fecha fin: 1 de Marzo de 2016

- Creación de ventana gráfica para la máquina de vectores soporte (SVM).
- Definición de métodos y estudio de posibilidades de aprendizaje para los resultados obtenidos en el análisis de datos.
- Reunión con tutor con el fin de entender la parte teórica de la aplicación para su posterior explicación en el punto tres de la documentación.
- Pruebas de dicho aprendizaje y corrección de errores de formato de archivos provenientes de la iteración dos.

- Pruebas con cada uno de los posibles kernels del método de aprendizaje (SVM): lineal, polinomial, RBF (Radial Basic Function) y sigmoide tahn.
- Documentación de esta fase

- ITERACIÓN 4

Fecha de inicio: 2 de Marzo de 2016

Fecha fin: 21 de Marzo de 2016

- Corrección de errores por no estar familiarizado con las máquinas vectores soporte.
- Revisión de la iteración tres.
- Desarrollo y corrección de métodos mal empleados en la anterior iteración.
- Reunión con tutor para solventar errores y afianzar conocimientos teóricos.
- Pruebas con otro tipo de máquinas vectores soporte como “libsvm” sin el resultado esperado.
- Documentación de esta fase.

- ITERACIÓN 5

Fecha de inicio: 22 de Marzo de 2016

Fecha fin: 10 de Abril de 2016

- Corrección de errores previos en la implementación.
- Variación del formato de entrada de datos resultantes del análisis de texturas.
- Comprobación de aprendizaje exitoso.
- Documentación de los cambios realizados.
- Solución de riesgos detectados.
- Desarrollo de prototipo final de la aplicación.
- Documentación de esta fase.

## **2.2.4 FASE DE TRANSICIÓN**

Fecha de inicio: 11 de Abril de 2016.

Fecha fin: 30 de Mayo de 2016.

Objetivos:

- Cumplimentación de la memoria final del proyecto.
- Correcciones de documentación.
- Volcado de documentación en la memoria.

- Correcciones pertinentes del tutor del proyecto.
- Complementación de la memoria con información de “papers médicos”.
- Estudio de la incorporación de funcionalidades nuevas.
- Presentación de dicha memoria al tutor de proyecto.
- Revisión de la memoria final del proyecto.
- Entrega final de memoria al tutor del proyecto.

## **CAPÍTULO 3. ANÁLISIS**

### **3 ANÁLISIS**

#### **3.1 ESPECIFICACIÓN DEL PROYECTO**

##### **3.1.1 PROCESAMIENTO DE IMÁGENES**

La descripción de la textura de una imagen ha constituido uno de los grandes temas en el campo del procesamiento de imágenes. Aunque no existe una definición formal de textura, intuitivamente se puede asociar a diversas propiedades de las imágenes, tales como suavidad, rugosidad, regularidad, etc. A veces se describe la textura de una imagen como la variación entre píxeles en una pequeña vecindad de dicha imagen. También se puede describir como un atributo que representa la distribución espacial de los niveles de intensidad en una región dada de una imagen digital. En ambas definiciones aparece el concepto de variación espacial en un entorno de vecindad, que es realmente el que se aplica en el presente trabajo. En cualquier caso, los enfoques utilizados para analizar las texturas son muy diversos, y difieren principalmente en el método utilizado para extraer las características de la textura. Básicamente se identifican cuatro categorías:

- 1) Métodos estructurales
- 2) Métodos basados en el modelo
- 3) Métodos basados en una transformada
- 4) Métodos estadísticos

- *Métodos estructurales*

Estas técnicas describen las texturas como la composición de elementos bien definidos, tales como líneas paralelas regularmente espaciadas o concatenaciones de figuras geométricas de formas conocidas tales como pentágonos. Requieren la definición de reglas que permitan diseñar tal encadenamiento.

- *Métodos basados en el modelo*

Estas técnicas se fundamentan en la construcción de un modelo empírico de cada píxel en la imagen basado en una suma ponderada de las intensidades de los píxeles en la vecindad del primero. Los parámetros estimados de los modelos así generados se utilizan como descriptores de las características de la textura.

- *Métodos basados en una transformada*

Estas técnicas convierten la imagen en una nueva forma o espacio utilizando las propiedades de frecuencia espacial de las variaciones de intensidad de los píxeles. La transformada más utilizada es la rápida de Fourier.

- *Métodos estadísticos*

Son técnicas que describen la textura de una imagen a través de los momentos estadísticos de orden superior basados en los correspondientes histogramas de niveles de intensidad. Dentro de los descriptores estadísticos se encuentran los basados en las denominadas matrices de co-ocurrencia.

Dentro de los métodos estadísticos habituales, existen dos variantes:

- i. Momentos del histograma (Método estadístico de primer orden)
- ii. Matriz de co-ocurrencia (Método estadístico de segundo orden)

Dichos métodos se basan en la distribución espacial de los niveles de gris, siendo el más simple el de los momentos del histograma, que se basa en utilizar los datos resultantes del histograma para definir niveles de gris en una imagen o una región. Dada la siguiente ecuación donde  $m$  es el valor medio de  $z$ , es decir el número de niveles:

“ $z$ ”: intensidad de una imagen discreta  $p(z_i) = 1, 2, \dots, L$  correspondiente al histograma, donde  $L$  es en número de niveles.

$$m = \sum_{i=1}^L z_i p(z_i)$$



El segundo momento, también denominado varianza, toma bastante importancia porque es la media del contraste del nivel de gris que se puede utilizar para establecer descriptores de suavidad relativa. El tercer momento es una media de la torsión del histograma, mientras que el cuarto es la monotonía relativa. El quinto momento, así como los siguientes no están relacionados con la forma del histograma, pero ofrecen una mayor discriminación cuantitativa del contenido de la textura. El procedimiento es el siguiente:

1. Se calcula el histograma de la imagen.
2. Si a cada valor del histograma se divide por el número total de píxeles de la imagen, se obtiene un histograma de probabilidades de nivel de gris “h” anteriormente descritas.

En el análisis de imágenes sólo por histogramas se desaprovecha la información correspondiente a la posición relativa de los píxeles entre sí, por lo que en este proyecto se ha decidido utilizar la matriz de co-ocurrencia para medir la cantidad de píxeles que se encuentran a una determinada distancia con un nivel de gris en común.

La matriz de co-ocurrencia  $P[i, j]$  se define especificando una dirección de desplazamiento  $d = (d_i, d_j)$  y contando todos los pares de píxeles separados por “d” y que tienen valores de gris “i” y “j”.

Para analizar texturas pueden calcularse diferentes matrices de co-ocurrencia de la misma imagen con valores diferentes de “d”. Los descriptores de textura son cálculos matemáticos obtenidos de la matriz de co-ocurrencia original de los niveles de gris de la imagen.

A continuación, se explicará el modo de obtener la matriz de co-ocurrencia y posteriormente el cálculo de los descriptores de textura.

### **3.1.2 DISEÑO DE LA MATRIZ DE CO-OCURRENCIA**

La matriz de co-ocurrencia describe la frecuencia de un nivel de gris que aparece en una relación espacial específica con otro valor de gris, dentro del área de una ventana determinada. La matriz de co-ocurrencia es un resumen de la forma en que los valores de los píxeles ocurren al lado de otro valor en una pequeña ventana.

Normalmente el procedimiento de generación de imágenes de textura consta de cinco variables:

- Tamaño de la ventana
- Banda espectral de entrada
- Las texturas derivadas
- Cuantización (número de bits) del canal de salida
- La componente espacial (distancia interpixel y el ángulo para el cómputo de la co-ocurrencia).

La ventana debe de ser cuadrada y con número impar de píxeles. El resultado del cálculo de la textura es un único número que representa la ventana completa, el cual es colocado en el lugar del píxel central. Luego, la ventana se mueve un píxel y el cálculo se repite calculando una nueva matriz de co-ocurrencia para esta nueva ventana y resultando un nuevo valor, para el píxel central de esta nueva posición de la ventana. De este modo se construye toda una nueva imagen con valores de texturas.

### 3.1.3 CONSTRUCCIÓN DE LA MATRIZ DE CO-OCURRENCIA

Supongamos una imagen de ejemplo como se muestra abajo que consta de 4 píxeles de lado y 4 niveles de grises: 0, 1, 2 y 3. Donde la direccionalidad es impuesta por los puntos cardinales.



0	0	1	1
0	0	1	1
0	2	2	2
2	2	3	3

La matriz de co-ocurrencia considera la relación espacial entre dos píxeles, llamados píxel de referencia y píxel vecino. Por ejemplo, si se escoge el píxel vecino que está situado un píxel a la derecha de cada píxel de referencia, 0 grados, esto se expresa como (1,0): 1 píxel en la dirección x, 0 píxel en la dirección y.

Para la representación de dichas direcciones al ser en parejas de píxeles, se interpreta dichas direcciones de la siguiente manera:

- (1,0) orientación horizontal, 0 grados.
- (0,-1) orientación vertical, 90 grados.
- (1,1) orientación diagonal hacia arriba, 45 grados.
- (1,-1) orientación diagonal hacia abajo, 135 grados.

Las posibles combinaciones se muestran en la siguiente tabla:

Píxel vecino(columnas) Píxel referencia (filas)	0	1	2	3
0	(0,0)	(0,1)	(0,2)	(0,3)
1	(1,0)	(1,1)	(1,2)	(1,3)
2	(2,0)	(2,1)	(2,2)	(2,3)
3	(3,0)	(3,1)	(3,2)	(3,3)

Cada píxel en la ventana se va convirtiendo sucesivamente en el píxel de referencia, empezando por el ubicado arriba a la izquierda y finalizando abajo a la derecha.

Existen, por lo tanto diferentes matrices de co-ocurrencia para cada relación espacial según la direccionalidad deseada. En el siguiente ejemplo consideraremos la relación espacial (1,0), es decir, horizontal.

0	0	1	1
0	0	1	1
0	2	2	2
2	2	3	3

Tabla 1

=

2	2	1	0
0	2	0	0
0	0	3	1
0	0	1	1

Tabla 2

La interpretación de la matriz es de la siguiente manera:

Se trata de contar el número de veces que aparece la combinación de dos números dada una dirección, y mostrar el resultado en la posición x, y de la matriz. En la matriz precedente, se cuenta cada píxel de referencia con su vecino a la derecha. Si el cálculo se realiza solo de este modo, usando sólo una dirección, entonces el número de veces que aparece la combinación (2,3) no es el mismo que la combinación (3,2) (por ejemplo el 3 está a la derecha del 2 una vez, pero a la izquierda ninguna), por lo tanto la matriz no es simétrica respecto de la diagonal. Ya que la simetría es necesaria para el correcto cálculo de la matriz de co-ocurrencia, se contará el par de píxeles dos veces, es decir, uno hacia la izquierda y otro hacia la derecha. Otro método de calcular dicha matriz resultante sería sumar a la matriz anterior su traspuesta, por lo que el resultado sería el siguiente:

Tabla 3

2	2	1	0
0	2	0	0
0	0	3	0
0	0	1	1



Tabla 4

2	0	0	0
2	2	0	0
1	0	3	1
0	0	0	1



4	2	1	0
2	4	0	0
1	0	6	1
0	0	1	2

Tabla 5

Una vez obtenido el resultado correspondiente a la matriz simétrica, se debe interpretar dichos valores como probabilidad. Para ello se calculará el número de la casilla correspondiente con el número total de casillas, es decir, el número de veces que se produce dicho evento partido por el número de eventos totales.

$$C_{i,j} = \frac{V_{i,j}}{\sum_{i,j=0}^{N-1} V_{i,j}}$$

Donde:

- “i” es el número de filas y “j” es el número de columnas
- V es el valor de la celda (i, j)
- $C_{ij}$  es la probabilidad en la celda (i, j)
- N es el número de filas o columnas.

Al ser una matriz de 4x4, hay 12 posibles pares entre ellos, por lo que tendremos que sumar los otros 12 de la matriz traspuesta y dan un resultado total de 24.

Dicho esto, nos dispondremos a calcular la matriz resultante con dichos parámetros:

$(4/24)=$ <b>0.166</b>	$(2/24)=$ <b>0.083</b>	$(1/24)=$ <b>0.042</b>	0
$(2/24)=$ <b>0.083</b>	$(4/24)=$ <b>0.166</b>	0	0
$1/24=$ <b>0.042</b>	0	$(6/24)=$ <b>0.25</b>	$(1/24)=$ <b>0.042</b>
0	0	$(1/24)=$ <b>0.042</b>	$(2/24)=$ <b>0.083</b>

Tabla 6

### 3.1.4 ASPECTOS A RESALTAR DE LA MATRIZ DE CO-OCURRENCIA

- 1) Los elementos de la diagonal representan pares de píxeles que no tienen diferencias en su nivel de gris. A cuanto más probabilidad, menos contraste ya que la mayoría de los píxeles vecinos son similares.
- 2) Al sumar los valores de la diagonal, obtenemos la probabilidad que un píxel tenga el mismo nivel de gris que su vecino.
- 3) Las líneas paralelas a la diagonal separadas una celda, representan los pares de píxeles con una diferencia de 1 en su nivel de gris. Esto conlleva que cuanto más nos alejemos de la diagonal, la diferencia entre niveles de gris será mayor.
- 4) La suma de la diagonal se denomina "GLDV" (Grey Level Difference Vector) y también es utilizado como medida textural.

### 3.1.5 MEDIDAS TEXTURALES PARA EL ANÁLISIS

Para medir la textura de las imágenes existen varias metodologías:

- **Primer orden:** son las calculadas a partir de los valores de gris originales de la imagen y su frecuencia, como la media, varianza, desviación estándar. En estas medidas no se considera la relación entre los píxeles.
- **Segundo orden:** medidas que consideran la relación de co-ocurrencia entre dada una orientación y una distancia a grupos de dos píxeles en una imagen original.
- **Tercer y más Orden:** se consideran las relaciones entre 3 y más píxeles. Su cálculo es teóricamente posible aunque requiere un coste alto en tiempo y los resultados son difíciles de interpretar.

Se han calculado las variables texturales de segundo orden a partir de la matriz de co-ocurrencia del nivel de gris (GLCM), que se construye a partir del análisis de parejas de píxeles para una distancia y orientaciones dadas entre ellos:

- *Inverse Difference Moment (ISM)*: también llamada homogeneidad:

$$\sum_{i,j=0}^{N=1} \frac{P_{ij}}{1 + (i - j)^2}$$

En general, cuanto mayor es el número de la diagonal en la matriz de co-ocurrencia, más homogénea es la textura en esa parte de la imagen que está siendo analizada.

- *Contraste*: es la cantidad de variaciones locales en los tonos de gris de la imagen. Cuanto mayor es la variación de los tonos de gris, mayor es el contraste:

$$\sum_{i,j=0}^{N=1} P_{ij}(i - j)^2$$

- *Correlación* : es la dependencia lineal de los tonos de gris en la imagen:

$$\sum_{i,j=0}^{N=1} P_{ij} \frac{(i - \mu_i)(j - \mu_j)}{\sqrt{\sigma_i \sigma_j}}$$

Si la correlación es 0, no existe correlación lineal entre los niveles de gris.

- *Entropía*: Es una medida de la complejidad de la imagen. A mayor entropía mayor complejidad:

$$\sum_{i,j=0}^{N=1} P_{ij}(-\ln P_{ij})$$

- La energía normalizada de una sub-imagen formada por N coeficientes se define como:

$$E_{ni} = \frac{1}{n} * \sum_{j*k} [D_{ni}(b_j, b_k)]^2$$

Donde  $E_{ni}$  refleja la distribución de energía a lo largo del eje de frecuencia sobre una escala y una orientación determinada.

### 3.1.6 DATOS ESTADÍSTICOS COMPLEMENTARIOS

- **Media:**

Cantidad total de la variable distribuida a partes iguales entre cada observación.

$$\bar{x} = \frac{1}{n} \sum_{i=1}^N a_i$$

- **Disimilitud:**

Falta de semejanza o de parecido entre dos o más muestras.

$$D = \sum_{i,j=0}^N |i - j| * C_{ij}$$

- **Kurtosis:**

Analiza el grado de concentración que presentan los valores alrededor de la zona central de la distribución.

$$g_2 = \frac{\left(\frac{1}{n}\right) * \sum (x_i - x_m)^4 * n_i}{\left(\frac{1}{n}\right) * \sum (x_i - x_m)^2 * n_i)^2} - 3$$

- **Media Geométrica:**

Medida similar a la media que viene dada por:

$$MG = \bar{x} = \sqrt[N]{X_1 * X_2 * ... * X_N}$$

- **Mediana:**

Representa el valor de la variable de posición central en el conjunto de datos ordenados dados.

$Me = x_{(n+1)/2}$  , si el número de muestras es impar.

$Me = x_{n/2}$  , si el número de muestras es par.

### 3.1.7 MÁQUINAS DE VECTORES SOPORTE.

Una Máquina de Vectores Soporte (SVM) nos permite determinar el hiperplano de separación de dos clases distintas (función de clasificación) a partir de unas muestras estadísticas de aprendizaje. La descripción dada por los datos de los vectores soporte nos permite construir una “frontera”, que actúa como delimitador de dos clases


distintas con poco o ningún conocimiento de los datos que están fuera de dicha frontera.

Dichos datos son mapeados por medio de un kernel Gaussiano u otro tipo de kernel a un espacio de características de mayor dimensión, es decir, proyectando dichas características en un plano con más dimensiones para su mejor separabilidad.

Dicha función busca la separación máxima entre las clases y es traída de regreso al espacio de entrada formando agrupamientos de clases.

### 3.1.8 CLASIFICACIÓN LINEAL SEPARABLE

Supongamos que nos han dado un conjunto  $S$  de puntos etiquetados para entrenamiento donde cada punto de entrenamiento  $x_i \in R^N$  pertenece a alguna de las dos clases y se le ha asignado una etiqueta  $y_i \in \{-1,1\}$  donde las muestras  $i = 1, \dots, l$ . Véase el ejemplo:



Este caso no es muy útil a la hora de una buena clasificación ya que las muestras reales por lo general son bastante dispares por lo que dicho método se vuelve bastante restrictivo. Una solución es mapear el espacio de entrada en un espacio de características de una dimensión mayor y buscar el hiperplano óptimo allí.

Supongamos que  $\mathbf{w}$  es la normal del hiperplano,  $\frac{|b|}{\|\mathbf{w}\|}$  es la distancia perpendicular del hiperplano al origen y  $\|\mathbf{w}\|$  es la normal euclídea de  $\mathbf{w}$  (distancia euclídea (en línea recta) entre dos puntos A y B que delimitan dicho vector  $\|\overrightarrow{AB}\| = \sqrt{(b1 - a1)^2 + (b2 - a2)^2}$ ))




Lo que se pretende es separar los puntos de acuerdo al valor de su etiqueta  $y_i$ , en dos hiperplanos diferentes:

- 1)  $W \cdot X_i + b + 1$  para  $y_i = 1$  (hiperplano positivo)
- 2)  $W \cdot X_i + b - 1$  para  $y_i = -1$  (hiperplano negativo)



Con lo cual quedaría de la siguiente manera:



Para simplificar el problema se suele utilizar la multiplicación de LaGrange, donde  $(\alpha) = (\alpha_1, \dots, \alpha_2)$  es un vector de multiplicadores de LaGrange.

$$L_p \equiv \frac{1}{2} \|\mathbf{w}\|^2 - \sum_{i=1}^l \alpha_i y_i (\mathbf{w} \cdot \mathbf{x}_i + b) + \sum_{i=1}^l \alpha_i$$

Cuando los datos no se pueden separar linealmente se hace un cambio de espacio mediante una función que transforme los datos de manera que se puedan separar linealmente. Tal función se llama **Kernel**.

### 3.1.9 CLASIFICACIÓN LINEAL NO SEPARABLE

Para el caso no lineal existen dos situaciones que vale la pena mencionar:

- a) El primero de estos se presenta cuando los datos pueden ser separables con margen máximo pero en un espacio de características (el cual es de una mayor dimensionalidad y se obtiene a través de una transformación a las variables del espacio de entrada) mediante el uso de una función **kernel**.

- b) El segundo caso especial de las SVM denominado “Soft Margin” o margen blando, es utilizado cuando no es posible encontrar una transformación de los datos que permita separarlos linealmente, bien sea en el espacio de entrada o en el espacio de características.

Hay casos donde los datos no pueden ser separados linealmente a través de un hiperplano óptimo en el espacio de entrada. En muchas situaciones, los datos, a través de una transformación no lineal del espacio de entradas, pueden ser separados linealmente pero en un espacio de características y se pueden aplicar los mismos razonamientos que para las SVM lineal con margen máximo. Dicha funcionalidad se logra a partir de la función kernel.

### 3.1.10 FUNCIONES KERNEL

El Kernel es un producto interno en el espacio de características desconocido, que tiene su equivalente en la entrada. Dicho producto interno tiene como objetivo distinguir una función kernel válida de la que no lo sea. Para ello existe la condición de “Mercer” que resuelve este interrogante.

Esta condición indica cuando una función puede ser empleada como kernel y cuando no, sin embargo no aporta información sobre cómo construir la función  $\phi$  (proyección) o cuál es el  $H$  (espacio).

- **Condición de “Mercer”:**

Existe una proyección  $\phi$  y una expansión  $K$ :

$$K(x, y) = \sum_i \phi(x)_i \phi(y)_i$$

Si y solo si, para cada  $g(x)$  tal que

$$\int g^2(x) dx < \infty$$

Entonces:

$$\int K(x, y) g(x) g(y) dx dy \geq 0$$

Al usar un kernel que no cumpla la condición de “Mercer” no estamos asegurando que el problema tenga solución aunque se puede dar el caso de trabajar correctamente con un conjunto de datos donde la frontera esté bien definida, y que por tanto, la máquina funcione bien. Aun así, aunque la solución sea correcta, la función Kernel carece de sentido.

Entre los **kernels** más comunes se encuentra:

- **Función lineal:**  $K(x, y) = a_1x + a_2y$
- **Polinomial:**  $K(x, y) = (x * y + 1)^p$
- **RBF (Radial Basic Function):**  $K(x, y) = e^{-\frac{\|x-y\|^2}{2\sigma^2}}$
- **Sigmoide tahn:**  $K(x, y) = \tanh(kx * y - \delta)$

### 3.1.11 TEORÍA DE LA GENERALIZACIÓN

El problema de identificación consiste en encontrar una función  $f(x)$  que se aproxime de manera óptima a una salida deseada  $y(x)$  siendo un conjunto de entrenamiento  $\{x_i, y_i\}_{i=1}^n$ , con la entrada  $x_i \in R^n$  y la salida  $y_i \in R^n$ , con función de probabilidad  $F(x, y)$ .

La función que dictamina como se penaliza el error de estimación se denomina función de costo:  $L(y_i, f(x))$ , por lo que el valor esperado de la función de costo se denomina función de **riesgo**:

$$R(w) = \int L(y_i, f(x)) dF_{x,Y}(x, y)$$

Evaluar la función de riesgo es complicado ya que no se suele conocer la función de distribución  $F_{x,Y}(x, y)$  y solo podemos usar el conjunto de entrenamiento hecho en el análisis para la identificación. Para solventar este problema podemos utilizar el principio de riesgo empírico el cual nos dice que en lugar de emplear la función de riesgo  $R(w)$  indicada anteriormente, podemos construir una función de riesgo empírico  $R_{emp}(w)$  de la siguiente forma:

$$R_{emp}(w) = \frac{1}{n} \sum_{i=1}^n L(y_i, f(x))$$

Dicha función se basa en un conjunto de entrenamiento independiente y nos indica que si  $w_{emp}$  minimiza a  $R_{emp}(w)$ , entonces  $R(w_{emp})$  converge en probabilidad al mínimo de todos los valores de  $R(w)$  siempre que sea uniforme. Este método es conocido como “Minimización del Error Empírico” y defiende que si el número de datos de entrenamiento “ $n \rightarrow \infty$ ”, entonces el riesgo empírico  $R_{emp}(w)$  converge a la función de riesgo  $R(w)$ .

Este método se utiliza cuando el espacio de muestras es muy grande, pero cuando tenemos el caso de no contar con un espacio de muestras tan amplio, se introduce un término nuevo a la función de riesgo empírico:

$$R_{emp}(w) = \frac{1}{n} \sum_{i=1}^n L(y_i, f(x)) + \frac{\lambda}{2} \|w\|^2$$

El término  $\|w\|^2$  controla la capacidad, esto es el error de generalización y  $\lambda > 0$  es una constante de regularización. Esta función se aproxima muy bien a la función de riesgo si se escoge adecuadamente la constante  $\lambda$ .

En la teoría de aprendizaje estadístico la minimización de la ecuación:

$$R_{emp}(w) = \frac{1}{n} \sum_{i=1}^n L(y_i, f(x)) + \frac{\lambda}{2} \|w\|^2$$

Se le conoce como minimización del riesgo estructurado.

### 3.1.12 VENTAJAS DE LAS MÁQUINAS DE VECTORES SOPORTE

Las Máquinas de vectores soporte utilizan un método inductivo que busca la minimización de riesgo estructural, usando una función **kernel** anteriormente definida. Dicha cualidad, le da una gran capacidad de generalización, incluso cuando el número de muestras es escaso.

Para el método de aprendizaje, no depende del número de atributos como hemos mencionado, por lo que en problemas con un número de muestras elevado, también cumple su función.

### 3.1.13 PROBLEMAS COMUNES CON MÁQUINAS DE VECTORES SOPORTE.

Uno de los problemas más comunes que surgen al trabajar con máquinas de vectores soporte es el sobre-entrenamiento, es decir, cuando el aprendizaje de los datos de entrada no construye un modelo discriminante fiable.

Esto conlleva una mala clasificación de los datos, por lo que es importante que el experimentador tenga en cuenta estas consideraciones a la hora de ajustar el modelo ya que de ello depende el éxito de la predicción.

## CAPÍTULO 4. DISEÑO

### 4 DISEÑO

#### 4.1 ESPECIFICACIÓN DEL DISEÑO

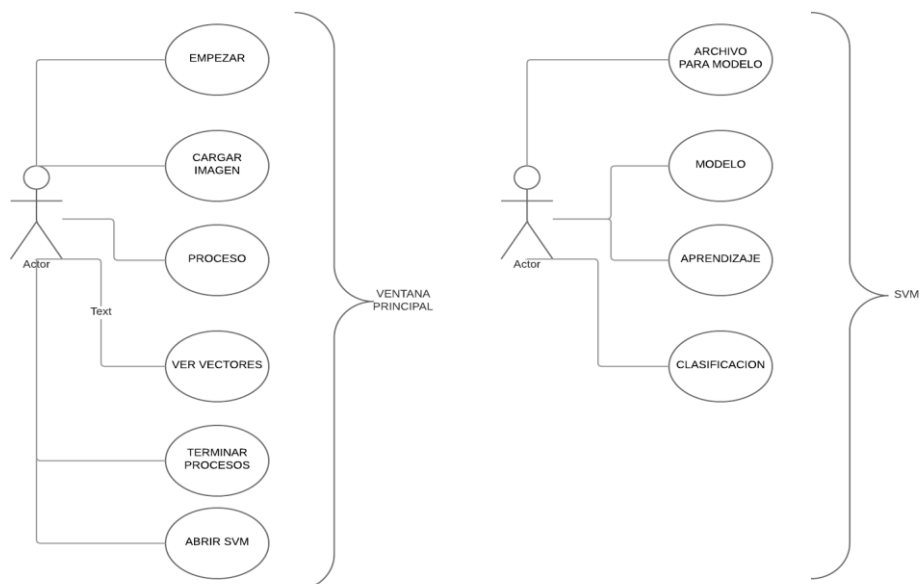
Para el uso de ésta aplicación, se seguirán las instrucciones especificadas en el anexo.

##### 4.1.1 DIAGRAMAS DE CASOS DE USO

La aplicación se divide en dos casos de uso diferentes ya que consta de dos partes: 1) Ventana principal, donde se llevará a cabo el análisis textural y 2) “SVM”, donde se llevará a cabo el aprendizaje automático.

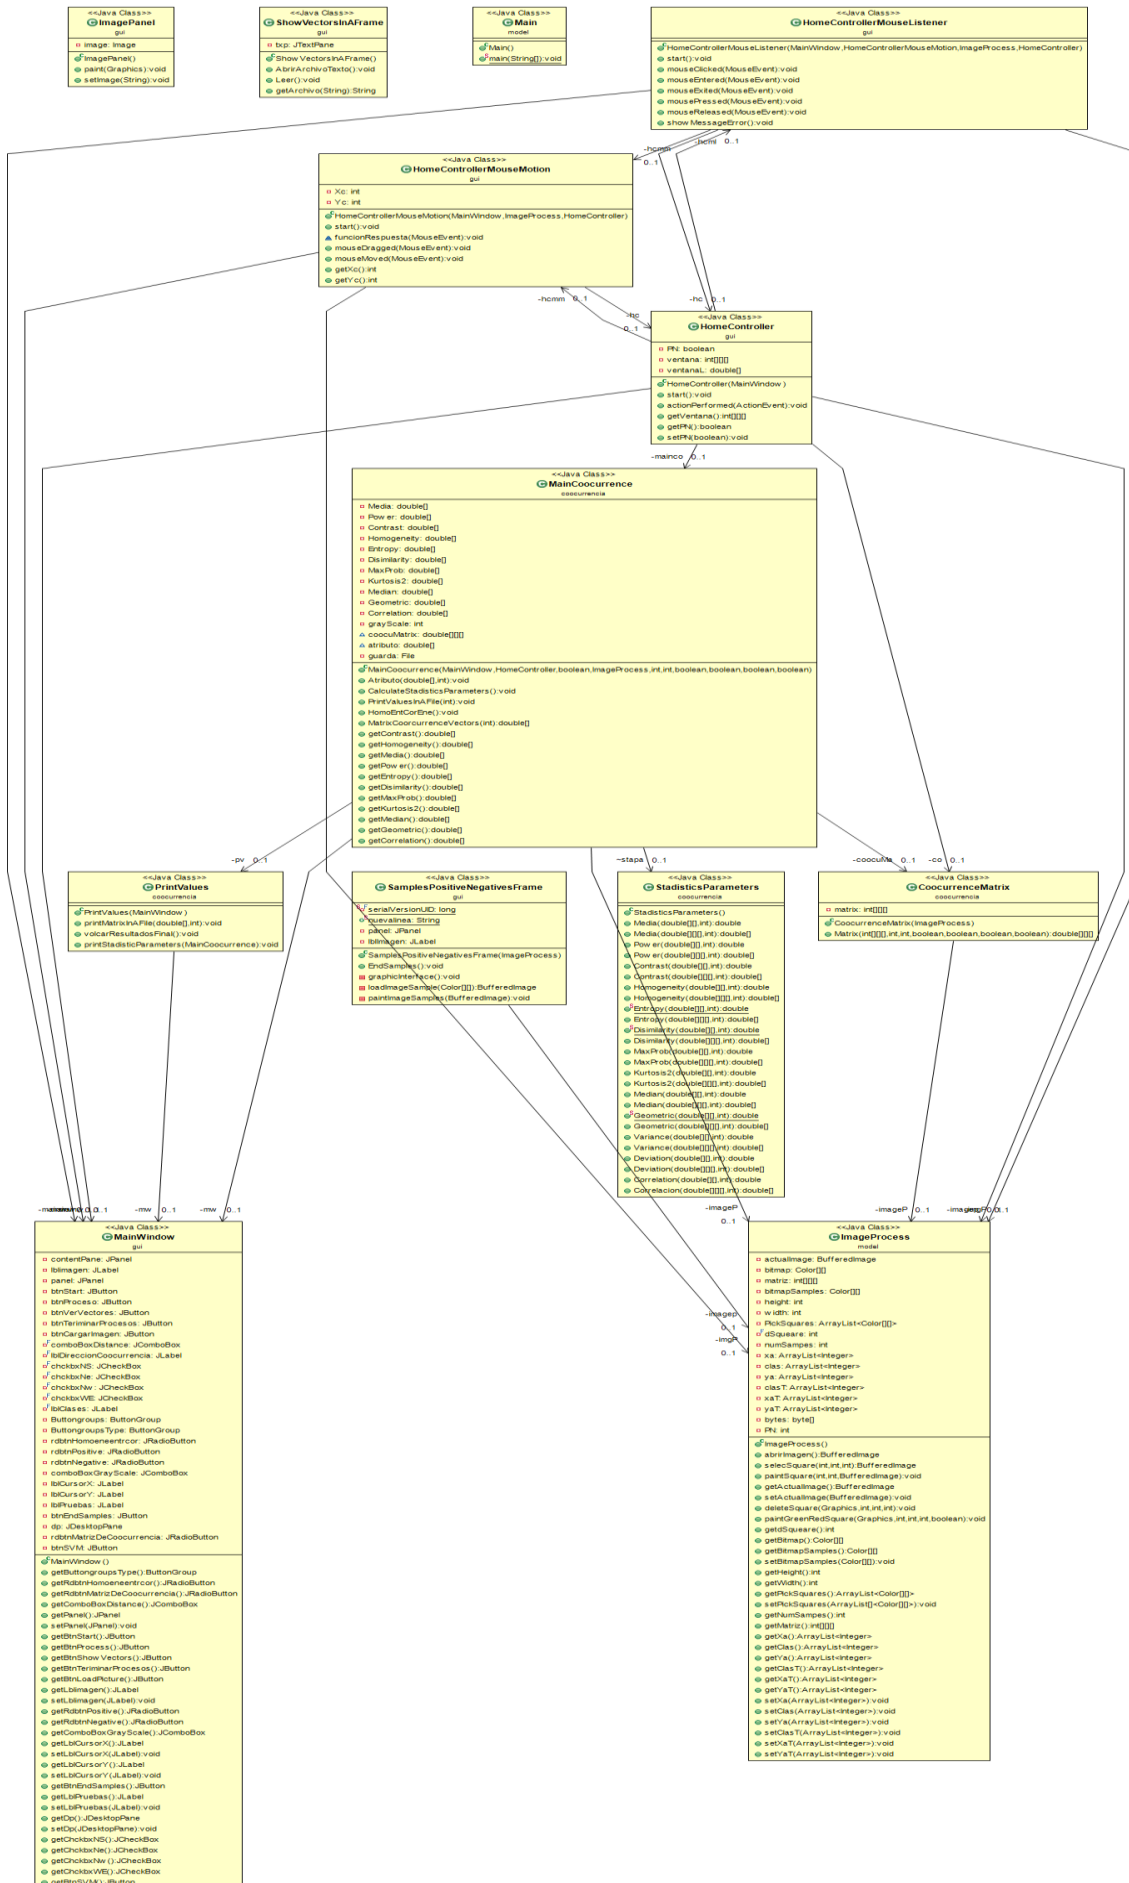
DIAGRAMA DE CASOS DE USO

Javier | May 2, 2016

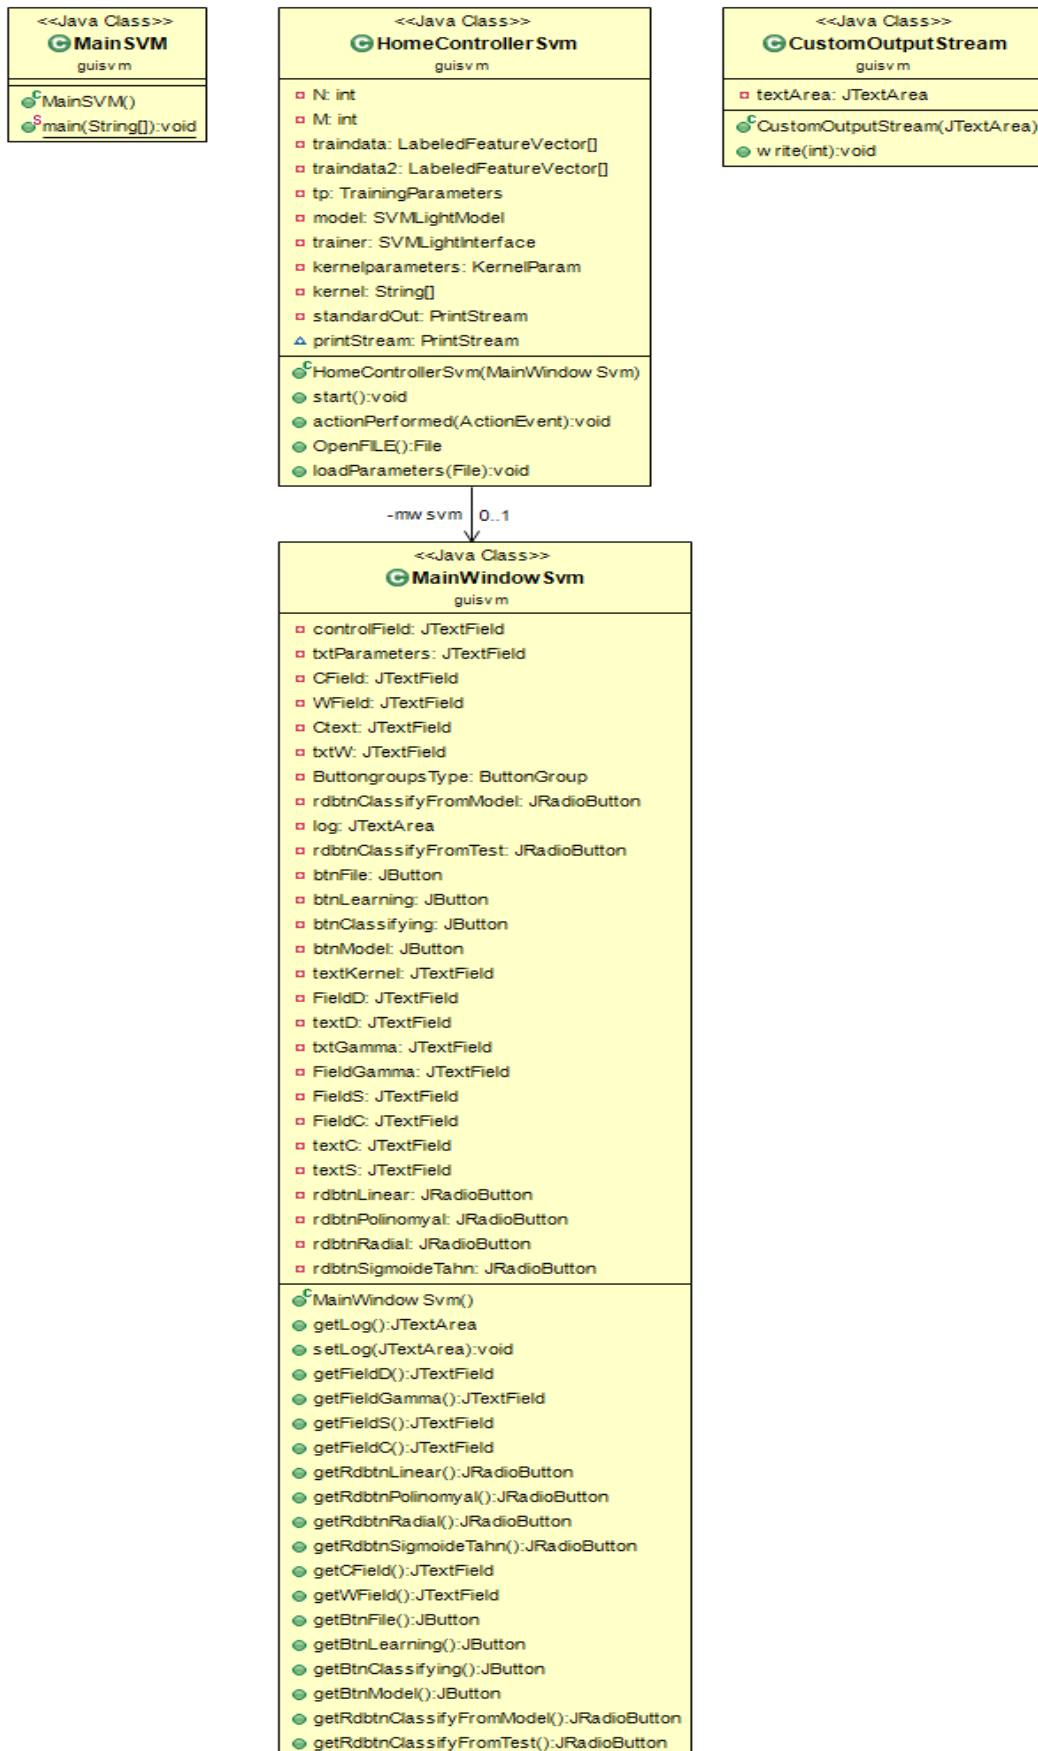


##### 4.1.2 DIAGRAMAS DE CLASE GENERAL

###### 4.1.2.1 ANÁLISIS DE TEXTURAS.

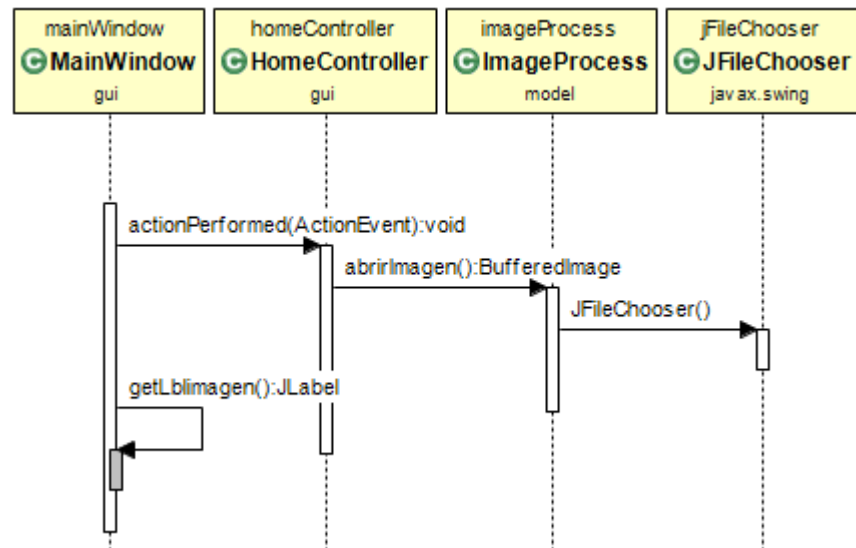


#### 4.1.2.2 SVM.

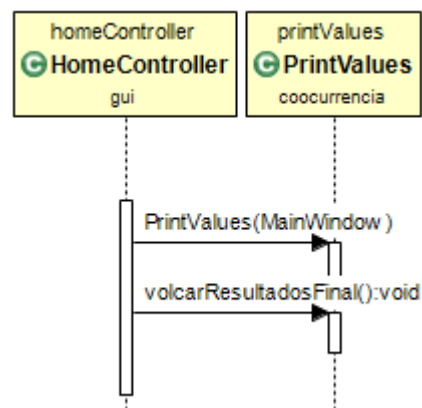


### 4.1.3 DIAGRAMAS DE SECUENCIA

#### 4.1.3.1 CARGAR IMAGEN

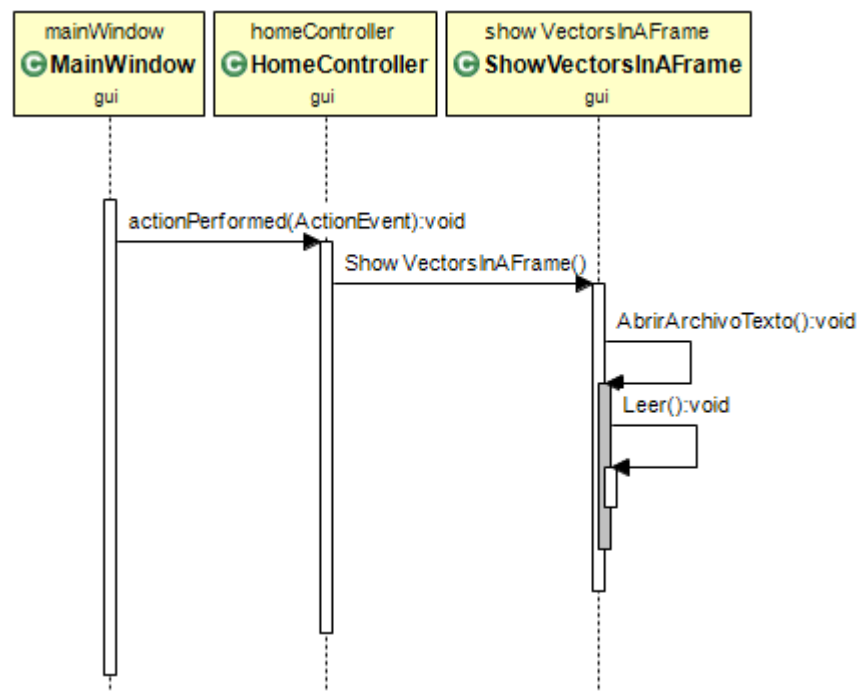


#### 4.1.3.2 TERMINAR PROCESOS

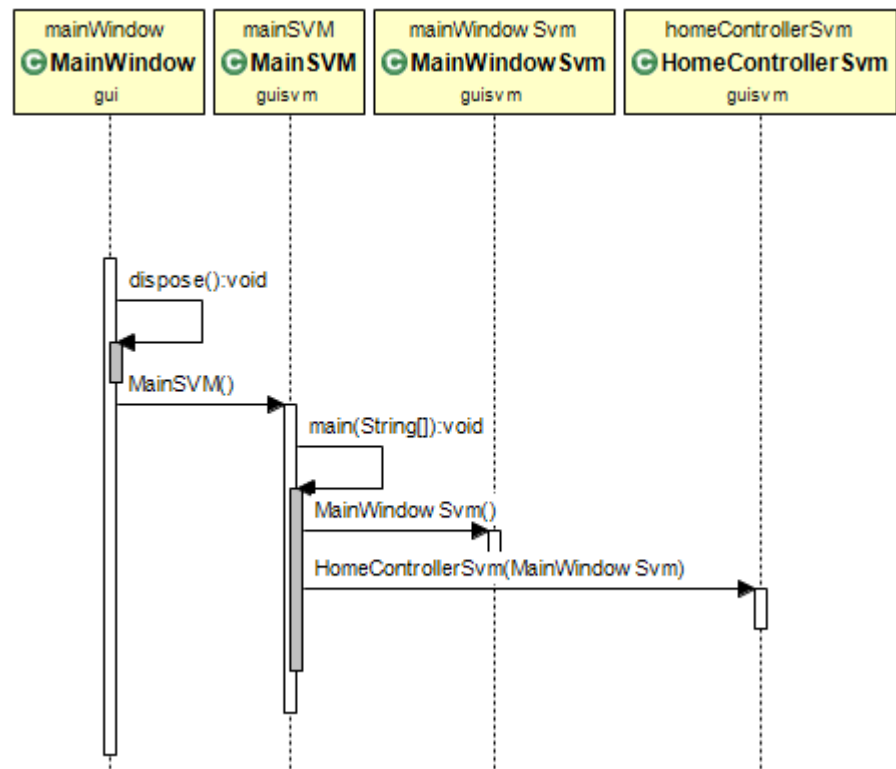




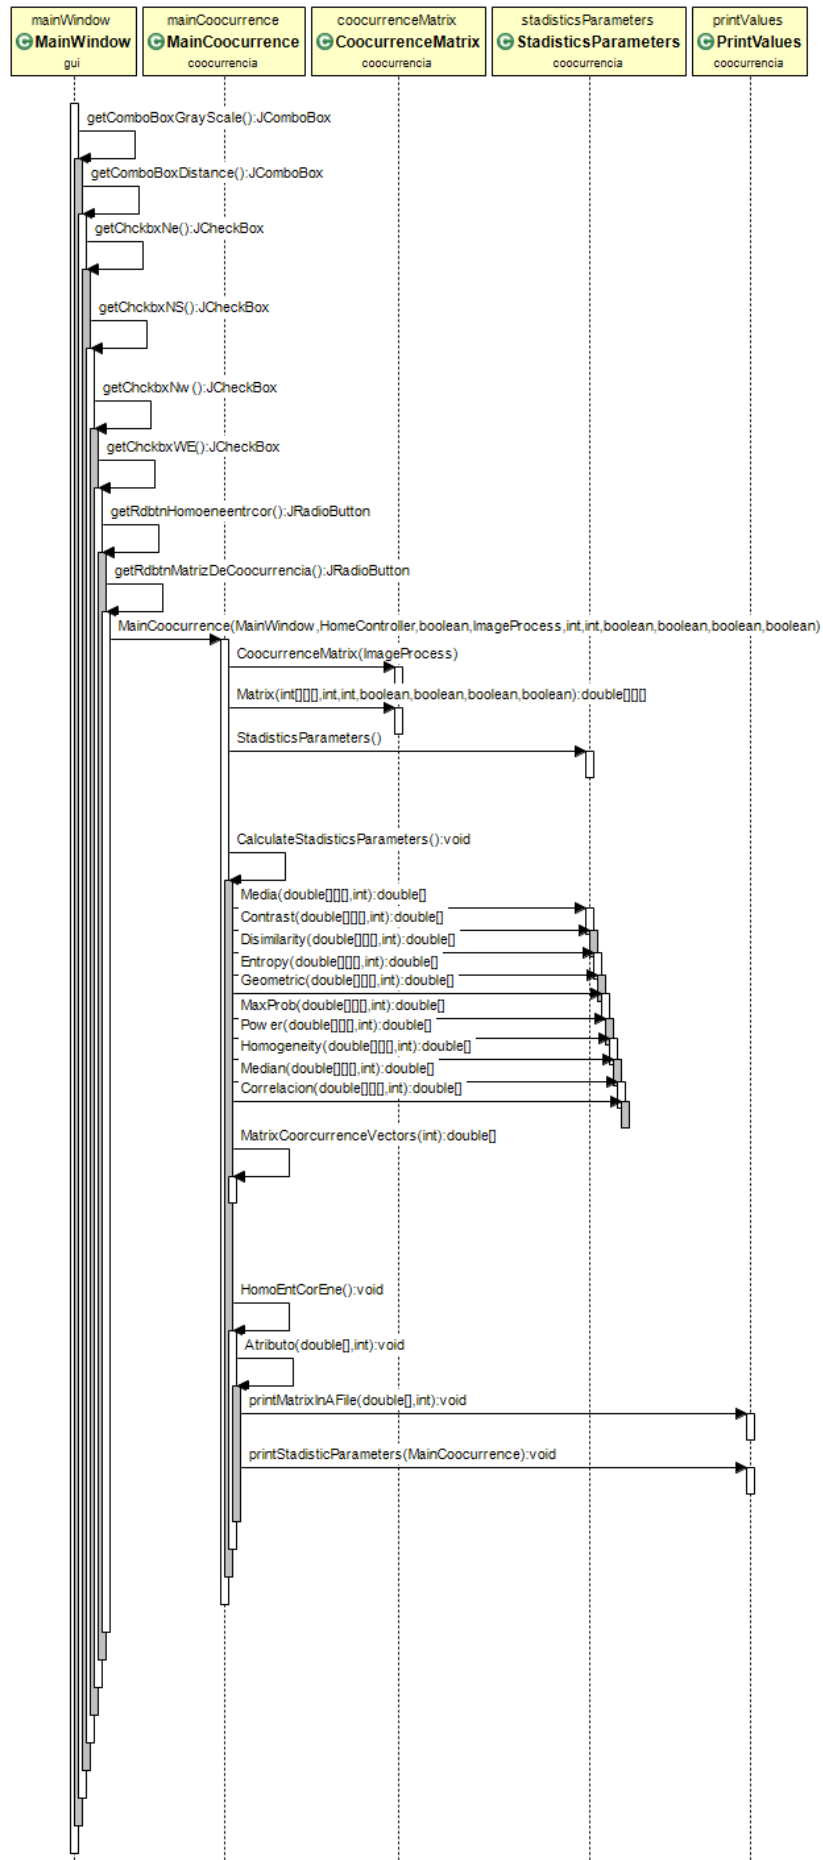
#### 4.1.3.3 VER VECTORES



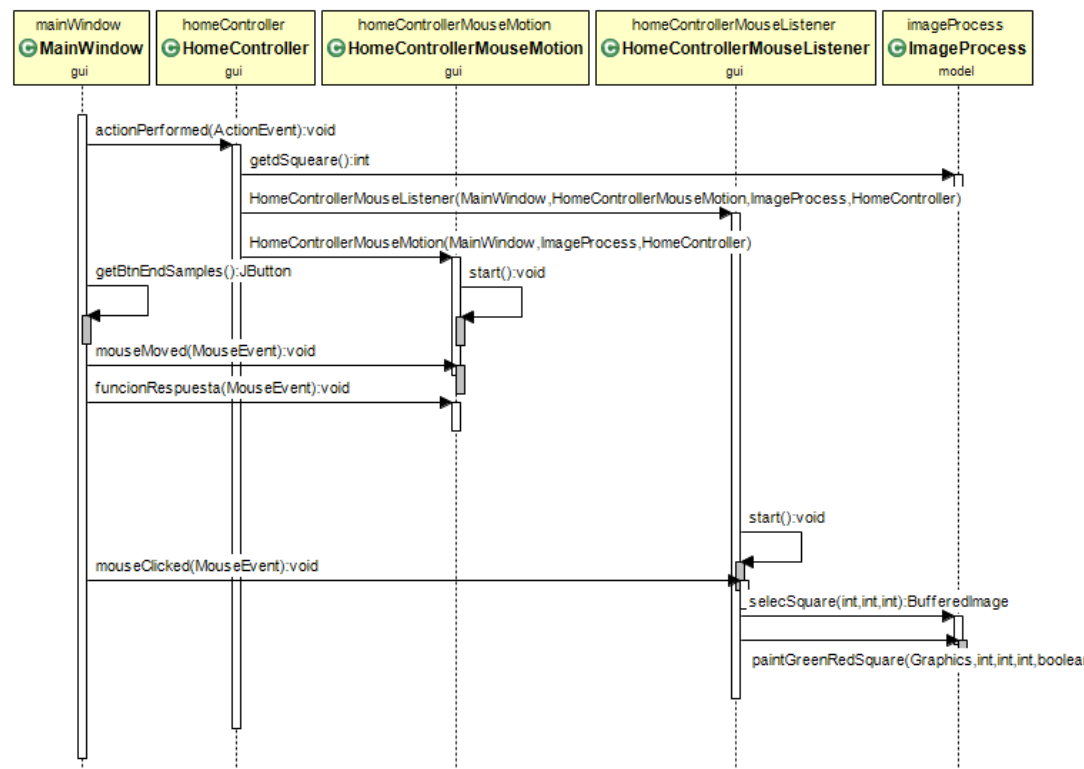
#### 4.1.3.4 ABRIR VENTANA SVM



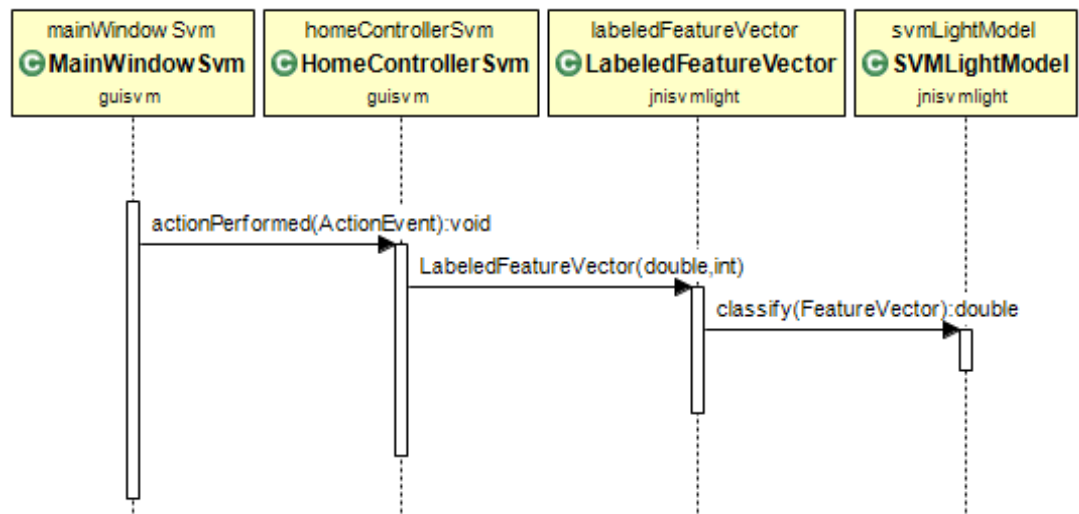
#### 4.1.3.5 PROCESO



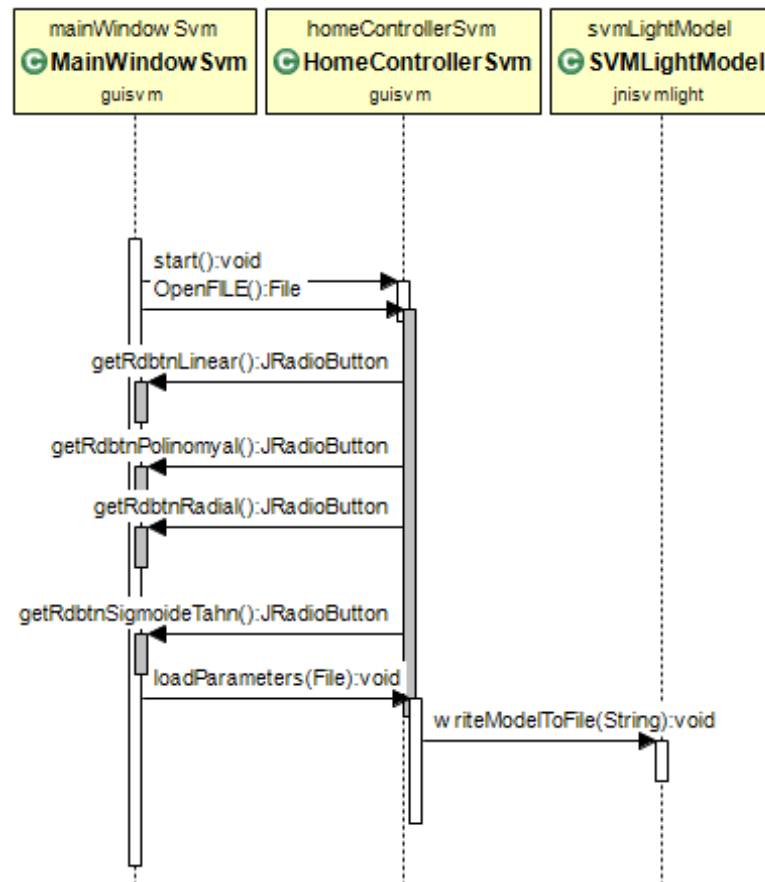
#### 4.1.3.6 EMPEZAR MUESTREO



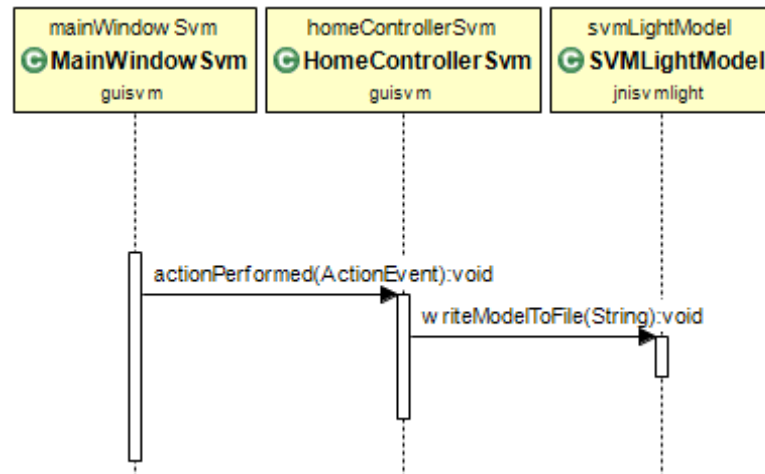
#### 4.1.3.7 CLASIFICAR



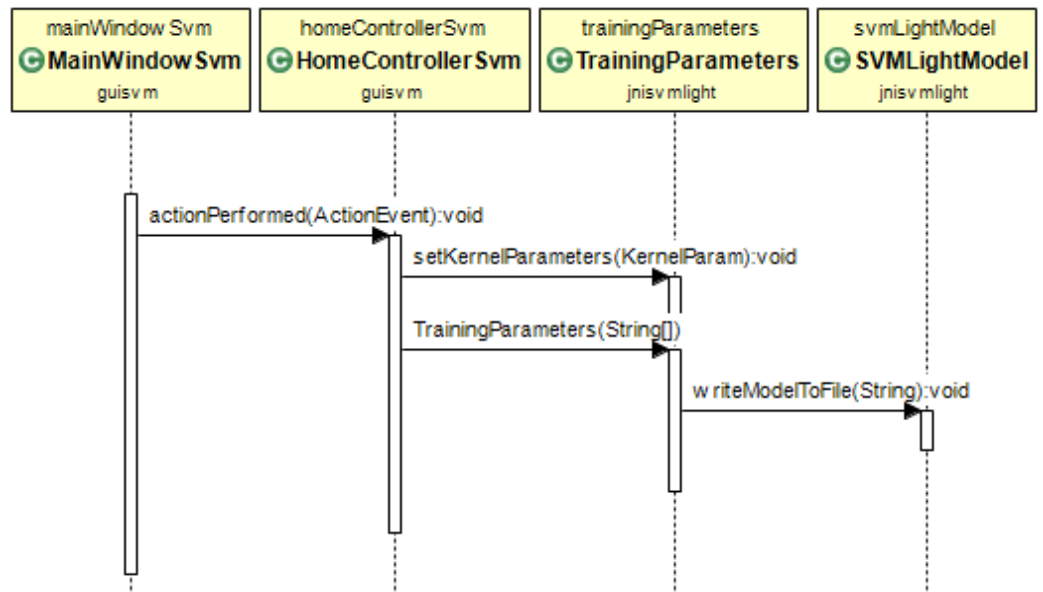
#### 4.1.3.8 CARGAR ARCHIVO PARA CREAR MODELO



#### 4.1.3.9 CARGAR MODELO



#### 4.1.3.10 APRENDIZAJE



## 4.2 RIESGOS

### 4.2.1 TECNOLÓGICOS

Riesgo	Probabilidad	Tipo	Descripción	Consecuencias	Resolución
Falta de librerías Java	Media	Predecible	Incompatibilidad de funcionalidad con el lenguaje	Graves	Búsqueda de documentación antes de programar.
Falta de memoria en las ejecuciones	Baja	Predecible	Violaciones de segmento o "stackoverflow" como respuesta del programa	Graves	Programación eficiente y optimización de código
Pérdida de Proyecto completo	Media	Impredecible	Pérdida de copia original y de seguridad del proyecto y la memoria	Muy Graves	Utilizar distintos repositorios como "Google Drive", "Dropbox" o unidades de almacenamiento externo.
Uso de versiones obsoletas	Baja	Predecible	Incorporación de código en versiones antiguas	Leves	Serialización de versiones
No encontrar fotografías válidas	Alta	Predecible	No encontrar las suficientes fotografías válidas para el aprendizaje automático	Media	Consultar Bases de datos de medicina

#### 4.2.2 CONOCIMIENTO

Riesgo	Probabilidad	Tipo	Descripción	Consecuencias	Resolución
Desconocimiento del lenguaje	Baja	Predecible	No tener constancia del uso del lenguaje empleado	Graves	Consultar manuales y apuntes de años anteriores
Desconocimientos teóricos	Alta	Predecible	Desconocimiento de la lógica teórica de la aplicación	Graves	Consultar a tutor con frecuencia
Organización y desarrollo de la memoria	Media	Predecible	Desconocimiento de la organización y el desarrollo de un trabajo de fin de grado	Leves	Consultar memorias de otros trabajos de fin de grado y consultar la página oficial de la universidad complutense de Madrid para salir de dudas.

#### 4.2.3 DISPONIBILIDAD DE REUNIÓN

Riesgo	Probabilidad	Tipo	Descripción	Consecuencias	Resolución
Compaginar trabajo y estudios	Alta	Predecible	Incompatibilidad de horarios para disponer de reuniones con el tutor	Muy Graves	Alargar el proyecto en la totalidad del curso académico.

## CAPÍTULO 5. RESULTADOS DEL PROYECTO Y CONCLUSIONES

### 5 RESULTADOS DEL PROYECTO Y CONCLUSIONES

#### 5.1 INTRODUCCIÓN.

En este capítulo se presentan los resultados más relevantes alcanzados como consecuencia de la investigación realizada y expuesta en esta memoria. Se explicarán las distintas salidas del programa para poder entender la conclusión final.

#### 5.2 RESULTADOS ESTADÍSTICOS.

Cada vez que el usuario pulsa el botón “Proceso”, el programa guarda en un fichero llamado “StadisticParameters.dat” los resultados estadísticos obtenidos en el análisis de la imagen.

El significado de los datos estadísticos son los siguientes:

- **Media:** La media de intensidad de una región no es en sí mismo un descriptor de textura, simplemente expresa el nivel medio de intensidad en la región. Éste dato es importante para el análisis ya que expresa el nivel medio del índice de la lesión para la región considerada.
- **Entropía:** La entropía es una medida de desorden de un sistema físico. Esta idea trasladada al contexto de las imágenes nos permite deducir que cuando en un entorno de vecindad alrededor de un píxel existe un alto grado de desorden, la entropía será mayor que cuando existe un cierto orden.
- **Disimilitud:** La obtención de agrupamientos naturales responde a muy diversos criterios. En general, el factor fundamental es el uso de una medida de disimilitud entre agrupamientos. Siguiendo esta medida, lo que se consigue es distinguir si dos muestras pertenecen al mismo agrupamiento (disimilitud baja) o no (disimilitud alta). Esta medida también se aplica de agrupamiento a agrupamiento, a fin de propiciar fusiones y separaciones entre los diversos agrupamientos obtenidos. El objetivo de esta medida es conseguir agrupamientos lo más adecuados posibles, por lo que es un índice bastante descriptivo para saber si en una lesión hay disimilitud entre distintas imágenes.
- **Geometría:** Define el porcentaje de reconocimiento de formas del muestreo indicándonos así, la uniformidad de la lesión.
- **Mediana:** Utilizada para eliminar ruido o detalles pequeños de poco interés puesto que sólo afecta a zonas con muchos cambios. Esta medida nos indicará el ruido de la imagen analizada.
- **Máxima Probabilidad:** Sobre cada una de las áreas de textura específica se han tomado muestras de aprendizaje de dos tipos, a saber, un primer

grupo para el entrenamiento de las muestras positivas y un segundo grupo para la evaluación de las muestras negativas. Éste indicador nos mostrará el máximo grado de probabilidad de encontrar muestras parecidas.

- **Energía:** Los valores de la matriz de co-ocurrencia son de probabilidades por lo que la ecuación de energía lo que hace es maximizar los valores grandes y minimizar los valores más pequeños. Esta medida nos indicará los picos obtenidos durante el análisis de la matriz de co-ocurrencia.
- **Homogeneidad:** Se dirá que si los valores de la diagonal de la matriz de co-ocurrencia son próximos a uno (1) entonces es una imagen suave y los que son cercanos a cero o nulo entonces se dirá que al no tener homogeneidad es una imagen tosca.
- **Kurtosis:** Es el grado de concentración que presentan los valores alrededor de la zona central de la distribución. Nos mostrará el grado de extensión de los dos tipos de muestras en la imagen.
- **Correlación:** La correlación será la medida que tomaremos para saber si las muestras negativas y las muestras positivas. Al ser dependencia lineal de los tonos de gris en la imagen, nos indicará el grado de diferencia entre ambas.

Los resultados vectores de características obtenidos por el análisis son los siguientes:

```
media:
 2.4414062500000634E-4 2.4414062500000634E-4 2.4414062500000634E-4
Entropia 5.069957189573834 5.069957189573834 5.069957189573834
Disimilitud 2.401923076923102 2.401923076923102 2.401923076923102
Geometria 0.0 0.0 0.0
Mediana 0.0 0.0 0.0
Maxima Probabilidad 0.03950320512820513 0.03950320512820513 0.03950320512820513
Energia 0.014315725673898856 0.014315725673898856 0.014315725673898856
Homogeneidad 0.38047534780003883 0.38047534780003883 0.38047534780003883
Kurtuosis 231.49928117469446 231.49928117469446 231.49928117469446
Correlacion -2.6910624903127E15 -2.6910624903127E15 -2.6910624903127E15

media:
 2.44140625E-4 2.44140625E-4 2.44140625E-4
Entropia 1.1372792307224802 1.1372792307224802 1.1372792307224802
Disimilitud 0.3485576923076923 0.3485576923076923 0.3485576923076923
Geometria 0.0 0.0 0.0
Mediana 0.0 0.0 0.0
Maxima Probabilidad 0.6230769230769231 0.6230769230769231 0.6230769230769231
Energia 0.4371759302062787 0.4371759302062787 0.4371759302062787
Homogeneidad 0.8292467948717949 0.8292467948717949 0.8292467948717949
Kurtuosis 3252.893100991264 3252.893100991264 3252.893100991264
Correlacion 9.278810578421615E14 9.278810578421615E14 9.278810578421615E14
```



media:  
 2.4414062500000016E-4 2.4414062500000016E-4 2.4414062500000016E-4  
Entropia 4.12598244700823 4.12598244700823 4.12598244700823  
Disimilitud 1.2830128205128206 1.2830128205128206 1.2830128205128206  
Geometria 0.0 0.0 0.0  
Mediana 0.0 0.0 0.0  
Maxima Probabilidad 0.0641025641025641 0.0641025641025641 0.0641025641025641  
Energia 0.022364873541255742 0.022364873541255742 0.022364873541255742  
Homogeneidad 0.49794337933478217 0.49794337933478217 0.49794337933478217  
Kurtuosis 277.6630979672963 277.6630979672963 277.6630979672963  
Correlacion 8.164316451290408E15 8.164316451290408E15 8.164316451290408E15

media:  
 2.4414062500000087E-4 2.4414062500000087E-4 2.4414062500000087E-4  
Entropia 4.518713377422892 4.518713377422892 4.518713377422892  
Disimilitud 2.0230769230769257 2.0230769230769257 2.0230769230769257  
Geometria 0.0 0.0 0.0  
Mediana 0.0 0.0 0.0  
Maxima Probabilidad 0.049679487179487176 0.049679487179487176 0.049679487179487176  
Energia 0.02064261793228139 0.02064261793228139 0.02064261793228139  
Homogeneidad 0.39388271022484556 0.39388271022484556 0.39388271022484556  
Kurtuosis 247.29492083952817 247.29492083952817 247.29492083952817  
Correlacion -2.1350732036694825E14 -2.1350732036694825E14 -2.1350732036694825E14

media:  
 2.4414062500000014E-4 2.4414062500000014E-4 2.4414062500000014E-4  
Entropia 3.9150921711589928 3.9150921711589928 3.9150921711589928  
Disimilitud 1.3386217948717982 1.3386217948717982 1.3386217948717982  
Geometria 0.0 0.0 0.0  
Mediana 0.0 0.0 0.0  
Maxima Probabilidad 0.08349358974358974 0.08349358974358974 0.08349358974358974  
Energia 0.036211515347633144 0.036211515347633144 0.036211515347633144  
Homogeneidad 0.524800340822798 0.524800340822798 0.524800340822798  
Kurtuosis 420.4518398724132 420.4518398724132 420.4518398724132  
Correlacion -1.55096044857859E15 -1.55096044857859E15 -1.55096044857859E15

media:  
 2.4414062500000003E-4 2.4414062500000003E-4 2.4414062500000003E-4  
Entropia 5.325086907154208 5.325086907154208 5.325086907154208  
Disimilitud 2.4376602564102594 2.4376602564102594 2.4376602564102594  
Geometria 0.0 0.0 0.0  
Mediana 0.0 0.0 0.0  
Maxima Probabilidad 0.024839743589743588 0.024839743589743588 0.024839743589743588  
Energia 0.0077905546309993395 0.0077905546309993395 0.0077905546309993395  
Homogeneidad 0.34525020242755056 0.34525020242755056 0.34525020242755056  
Kurtuosis 134.05854339865166 134.05854339865166 134.05854339865166  
Correlacion 3.1427276230570145E15 3.1427276230570145E15 3.1427276230570145E15

media:  
 2.4414062500000455E-4 2.4414062500000455E-4 2.4414062500000455E-4  
Entropia 5.094073772189721 5.094073772189721 5.094073772189721  
Disimilitud 2.1599358974359117 2.1599358974359117 2.1599358974359117  
Geometria 0.0 0.0 0.0  
Mediana 0.0 0.0 0.0  
Maxima Probabilidad 0.032532051282051284 0.032532051282051284 0.032532051282051284  
Energia 0.011255226310815335 0.011255226310815335 0.011255226310815335  
Homogeneidad 0.4140738734489792 0.4140738734489792 0.4140738734489792  
Kurtuosis 144.23436065053403 144.23436065053403 144.23436065053403  
Correlacion -1.9414686973500142E15 -1.9414686973500142E15 -1.9414686973500142E15

```

media:
  2.441406250000001E-4 2.441406250000001E-4 2.441406250000001E-4
Entropia 2.3854676373559367 2.3854676373559367 2.3854676373559367
Disimilitud 0.5985576923076923 0.5985576923076923 0.5985576923076923
Geometria 0.0 0.0 0.0
Mediana 0.0 0.0 0.0
Maxima Probabilidad 0.2298076923076923 0.2298076923076923 0.2298076923076923
Energia 0.12657808904503612 0.12657808904503612 0.12657808904503612
Homogeneidad 0.719610671191554 0.719610671191554 0.719610671191554
Kurtuosis 1046.981213219471 1046.981213219471 1046.981213219471
Correlacion -3.3869090348019615E15 -3.3869090348019615E15 -3.3869090348019615E15

media:
  2.44140625E-4 2.44140625E-4 2.44140625E-4
Entropia 1.3791073429560048 1.3791073429560048 1.3791073429560048
Disimilitud 0.4302884615384615 0.4302884615384615 0.4302884615384615
Geometria 0.0 0.0 0.0
Mediana 0.0 0.0 0.0
Maxima Probabilidad 0.36362179487179486 0.36362179487179486 0.36362179487179486
Energia 0.26560510920036157 0.26560510920036157 0.26560510920036157
Homogeneidad 0.7851762820512822 0.7851762820512822 0.7851762820512822
Kurtuosis 1356.347639630654 1356.347639630654 1356.347639630654
Correlacion 6.722465765279704E14 6.722465765279704E14 6.722465765279704E14

media:
  2.4414062500000006E-4 2.4414062500000006E-4 2.4414062500000006E-4
Entropia 4.846934853390926 4.846934853390926 4.846934853390926
Disimilitud 2.188782051282052 2.188782051282052 2.188782051282052
Geometria 0.0 0.0 0.0
Mediana 0.0 0.0 0.0
Maxima Probabilidad 0.0266025641025641 0.0266025641025641 0.0266025641025641
Energia 0.01053023298816568 0.01053023298816568 0.01053023298816568
Homogeneidad 0.377924655798749 0.377924655798749 0.377924655798749
Kurtuosis 99.20768060092404 99.20768060092404 99.20768060092404
Correlacion 6.6524458090932448E16 6.6524458090932448E16 6.6524458090932448E16

media:
  2.441406250000023E-4 2.441406250000023E-4 2.441406250000023E-4
Entropia 4.071252018539624 4.071252018539624 4.071252018539624
Disimilitud 2.110416666666674 2.110416666666674 2.110416666666674
Geometria 0.0 0.0 0.0
Mediana 0.0 0.0 0.0
Maxima Probabilidad 0.06987179487179487 0.06987179487179487 0.06987179487179487
Energia 0.03174245459401689 0.03174245459401689 0.03174245459401689
Homogeneidad 0.410753796621385 0.410753796621385 0.410753796621385
Kurtuosis 339.55466875874447 339.55466875874447 339.55466875874447
Correlacion 2.6257610056676806E14 2.6257610056676806E14 2.6257610056676806E14

```

Obtenidos del archivo "StadisticParameters.dat".

### 5.3 CONCLUSIÓN.

El proyecto realizado ha seguido el ciclo de vida típico de cualquier aplicación que se puede desarrollar a nivel educativo o empresarial, intentando poner en práctica técnicas de ingeniería del software y afianzando distintos conceptos

aprendidos durante la carrera tales como el uso de patrones (MVC) o documentación utilizando diagramas de clases.

Respecto a los objetivos, se han cumplido todos y cada uno de ellos y han quedado descritos en los puntos 3, 4 y 5 de este mismo documento.

En cuanto al análisis, el método de las matrices de co-ocurrencia de nivel de grises perteneciente al análisis de textura ha resultado ser exitoso en la segmentación de imágenes médicas. Durante el desarrollo del proyecto han surgido inconvenientes los cuales me han llevado a la conclusión de puntos muy interesantes acerca del análisis de textura.

En el momento en el que se analizan las imágenes se deben tener en cuenta la tonalidad y dimensión de las mismas ya que, durante el inicio del proyecto se emplearon imágenes de una misma patología obtenidos de internet y variaban en las características ya mencionadas. Estos análisis dieron lugar a conclusiones erróneas y datos contradictorios en cuanto la discriminación empleada en el muestreo de las fotografías.

Para ello, hay varios puntos que deben ser considerados para el análisis mediante esta técnica.

- En primer lugar, es importante considerar el tamaño de las imágenes analizadas ya que influye directamente en el veredicto del sistema. Al probar imágenes de distintos tamaños, el resultado de la clasificación es de poca utilidad, ya que al analizar una distancia y direccionalidad constante en fotografías en las que se han tomado de distinta manera, el resultado final no es concluyente.
- En segundo lugar, la tonalidad de la imagen debe ser la misma en todos los casos a analizar ya que, al medir escalas de grises, el resultado puede variar considerablemente según la intensidad del foco utilizado para la obtención de la imagen.
- Por ello, es recomendable utilizar imágenes obtenidas de una misma máquina, con un tamaño e iluminación constante.

A partir de la conclusión anterior, se decidió utilizar imágenes extraídas del archivo del hospital Clínico San Carlos para lidiar con los problemas antes mencionados.

El resultado de la clasificación con una imagen de prueba sobre un modelo ya creado ha sido satisfactorio, puesto que ha conseguido clasificar con una efectividad del 99%. Aunque hay que tener en cuenta que cuanto mayor sea la escala de grises y la distancia, el tiempo de compilación puede ser muy largo por lo que baja la eficiencia del programa (Punto 7.3).

Finalmente, el tamaño de las muestras es de 40 píxeles, un tamaño que he creído conveniente ya que las muestras elegidas con un tamaño menor siempre surgían errores en las regiones de píxeles seleccionadas, así como en la clasificación de los mismos.

## 5.4 CONCLUSION.

The project undertaken has followed the typical life cycle of any application that can develop educational or business level, trying to put into practice techniques of software engineering and consolidating various concepts learned during the race such as the use pattern ( MVC ) or documentation using class diagrams.

Regarding the objectives they have been met and every one of them and have been described in paragraphs 3, 4 and 5 of this document.

For analysis, the method of co-occurrence matrices gray level pertaining to texture analysis has proved successful in medical image segmentation. During the project's development problems they have arisen which have led me to conclude very interesting points about texture analysis.

In the moment when the images are analyzed must take into account the tone and the same dimension, as during the beginning of the project I used images of the same pathology of Internet and they varied in the aforementioned characteristics. These analyzes led to erroneous conclusions and contradictory data regarding discrimination used in the sampling of photographs.

To do this, there are several points that should be considered for analysis using this technique.

- First, it is important to consider the size of the images analyzed as it directly influences the verdict of the system. When testing images of different sizes, the result of classification is of little use, because when analyzing a constant distance and directionality in photographs that have been taken differently, the end result is inconclusive.
- Second, the tonality of the image must be the same in all cases to analyze because, when measuring grayscale, the result can vary considerably depending on the intensity of the focus used to obtain the image.
- It is therefore advisable to use images obtained from a single machine, with a size and constant illumination.

From the above conclusion, it was decided to use images from the archive of the hospital Clínico San Carlos to deal with the above problems.

The result of the leaderboard with a test image on a model already created has been satisfactory, since it has managed to classify an effectiveness of 99 %. Although we must bear in mind that the larger the greyscale and distance, compilation time can be very long so low efficiency of the program (Point 7.3).

Finally, the sample size is 40 pixels, a size that I thought convenient as selected samples with a smaller size, always arose errors in selected regions of pixel , and ranking them.

## CAPÍTULO 6. BIBLIOGRAFÍA

### 6 BIBLIOGRAFÍA

- i. *Capítulo 5: Caracterización de Texturas. Métodos Estadísticos Basados en la transformada Wavelet. Escuela Superior de Ingenieros de Sevilla. "Extracción de características de textura basada en la transformada Wavelet discreta ".*  
<http://bibinq.us.es/proyectos/abreproy/11494/fichero/PROYECTO%252FCa pitulo+5.pdf>
- ii. *Fatima Eddaoudi, Fichita Regragui, Abdelhak Mahmoudi, Najib Lamiare Masses Detection Using SVM Classifier, Based on Textures Analysis Applied Mathematical Sciences, Vol. 5, 2011, no. 8, 367 – 379.*
- iii. *Ríos-Díaz, José; Martínez-Payá, Jacinto Javier; Baño Aledo, M<sup>a</sup> Elena del El análisis textural mediante las matrices de co-ocurrencia (GLCM) sobre imagen ecográfica del tendón rotuliano es de utilidad para la detección cambios histológicos tras un entrenamiento con plataforma de vibración:*  
<http://www.redalyc.org/articulo.oa?id=163013077004>
- iv. *Pablo Barrera González, Dr. Ángel Navia Vázquez .Máquinas de vectores soporte para procesamiento de secuencias: el kernel de Fisher en secuencias bioinformáticas.*
- v. *Juan Sebastián Botero Valencia, Alejandro Restrepo Martínez ANÁLISIS DE TEXTURA EN PANES USANDO LA MATRIZ DE COOCURRENCIA: Revista Politécnica ISSN 1900-2351, Año 6, Número 10, 2010.*
- vi. *Loris Nanni, Sheryl Brahnam, Stefano Ghidoni, Emanuele Menegatti, Tonya Barrier, Different Approaches for Extracting Information from the Co-Occurrence Matrix.*
- vii. *Fernández Sarría, A., Recio, J., Ruiz Fernández, L. A. (2003): "Análisis de imágenes mediante texturas: aplicación a la clasificación de unidades de vegetación", GeoFocus (Artículos), n<sup>o</sup> 3, p. 143-159. ISSN: 1578-5157.*
- viii. *José Luís Gil Rodríguez, RT\_004 Julio 2008 Estado Actual de la Representación y Análisis de Textura en Imágenes. Serie Azul RNPS No. 0551.*
- ix. *Iglesias Marcos, Pablo (2010) Estrategias de clasificación de texturas en imágenes forestales hemisféricas. [Trabajo Fin de Máster].*
- x. *G Pajares, JM De La Cruz - Pattern recognition, 2004.*

- xi. Stereoscopic analysis and texture recognition in forest images acquired by the device MU-200501738 (2008)*

## **CAPÍTULO 7. ANEXO Y RESULTADOS DE LAS PRUEBAS.**

### **7 ANEXO Y RESULTADOS DE LAS PRUEBAS.**

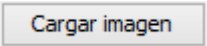
#### **7.1 MANUAL DE USUARIO ANÁLISIS DE IMAGEN:**

Para los resultados obtenidos que se mostrarán a continuación si ha utilizado los siguientes parámetros:


- Gray Scale: 64.
- Distance: 2.
- Direccionalidad: NW, NS, NE, WE.
- Tipo de atributo: Matriz de co-ocurrencia.

##### **7.1.1 Cargar imagen.**

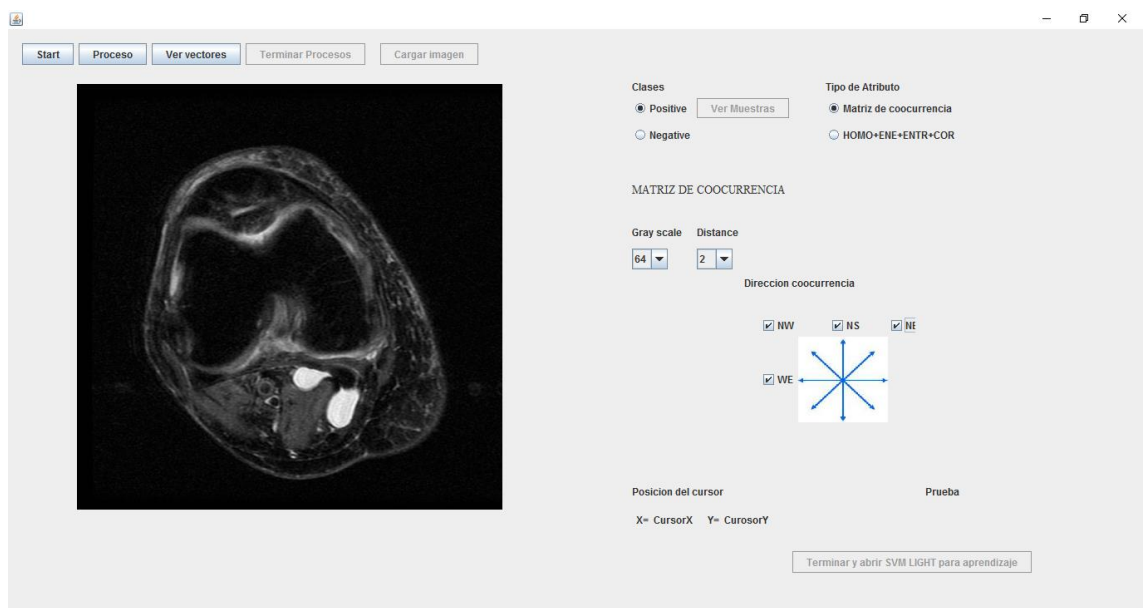
El primero paso para el uso de esta aplicación es cargar una imagen para su posterior análisis.

Para ello tendremos que pulsar el botón:  . Una vez pulsado, nos mostrará la siguiente ventana, donde seleccionaremos la ruta de la imagen deseada para analizar:





Una vez seleccionada la imagen pulsamos el botón abrir y acto seguido aparecerá la imagen en la aplicación:



### 7.1.2 Seleccionar muestras de la imagen.

El segundo paso es seleccionar las muestras positivas y negativas de dicha imagen, con una serie de configuraciones previas aquí descritas:

- Elegiremos el tipo de atributo que analizará de la muestra, es decir si Matriz de Co-ocurrencia o (Homogeneidad + Energía + Entropía + Correlación).

**Tipo de Atributo**

☒ Matriz de coocurrencia

☐ HOMO+ENE+ENTR+COR

- Acto seguido, seleccionaremos la distancia entre pixeles y la escala de grises sobre el que se va a basar el análisis:

**Gray scale**    **Distance**

64 ▼    2 ▼

- Si el tipo de atributo seleccionado es Matriz de Co-ocurrencia, tendremos que seleccionar la direccionalidad deseada para el análisis de dichos pixeles:

**Direccion coocurrencia**

☒ NW    ☒ NS    ☒ NE

☒ WE



El diagrama muestra un punto central con ocho flechas azules que se extienden en las direcciones NW, NS, NE, E, SE, S, SW y W. Las flechas NW, NS, NE y WE están seleccionadas, lo que se refleja en los checkboxes marcados.

Una vez seguidos los pasos anteriores procederemos a muestrear la imagen deseada, para ello pulsaremos el botón **Start** y haremos “click” dentro de la imagen para la selección de las muestras. Para cambiar de positiva a negativa seleccionaremos en cualquier momento

**Clases**

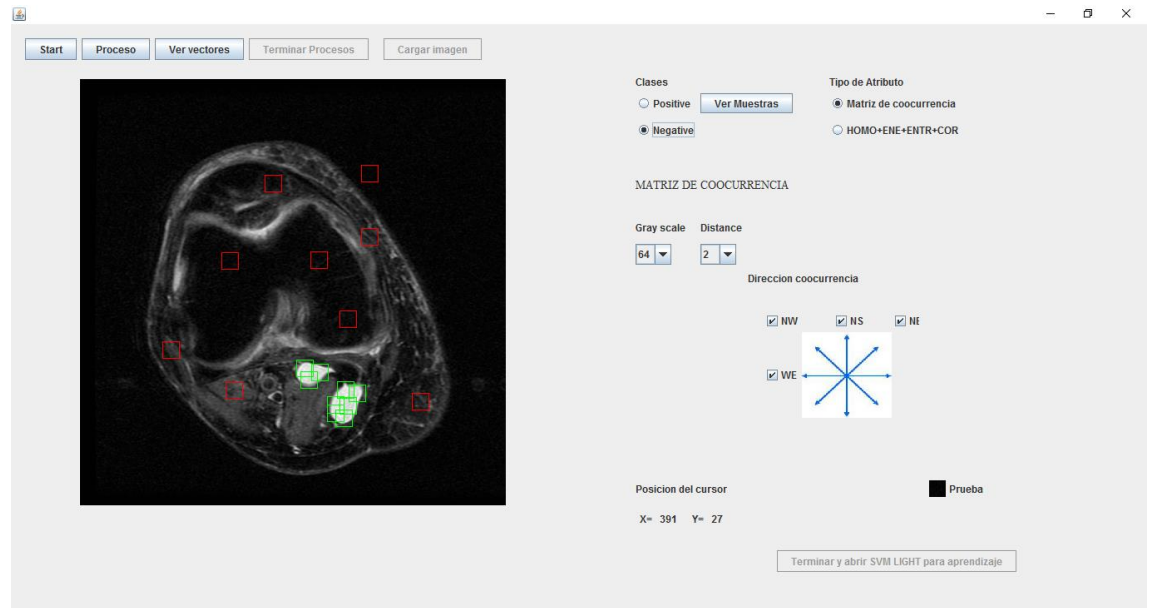
☒ Positive

☐ Negative

en este panel: la clase deseada.

Una vez muestreada la imagen quedaría algo parecido a lo siguiente:





Donde los cuadrados con borde verde son las muestras positivas y los cuadrados con borde rojo son las muestras negativas.

Si se desea cargar otra imagen deberá cerrarse el programa y volverse a abrir.

### 7.1.3 Ver Muestras.


Para visualizar más en detalle las muestras extraídas de la imagen,

haremos “click” en el botón: **Ver Muestras**, y nos mostrará una ventana nueva con las muestras elegidas:



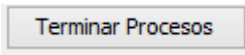
#### 7.1.4 Proceso.

Una vez terminado el muestreo, procederemos a volcar la información en un archivo para su posterior aprendizaje o clasificación. El botón



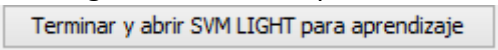
, separará las muestras positivas y negativas en dos archivos diferentes para que cuando muestreemos otras imágenes, se guarden en dichos archivos por separado las muestras positivas de las negativas.

#### 7.1.5 Terminar Procesos.

Para finalizar los procesos, se pulsará el botón  cuya funcionalidad es juntar en un archivo en común los resultados positivos y negativos para la creación de un modelo que servirá a la máquina de vectores soporte como base de clasificación y/o aprendizaje.

Al terminar los procesos, se generará un archivo llamado `StatisticParameters.dat` el cual nos mostrará los resultados estadísticos de las operaciones realizadas.

#### 7.1.6 Terminar y abrir SVM LIGHT para aprendizaje.

Por último pasaremos a la interfaz gráfica de la máquina de vectores soporte mediante éste botón: .

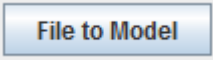
## 7.2 MANUAL DE USUARIO APRENDIZAJE AUTOMÁTICO

Los resultados que se muestran a continuación, han sido extraídos del análisis de once imágenes con un total de 176 muestras, la mitad de ellas negativas y la otra mitad positivas.

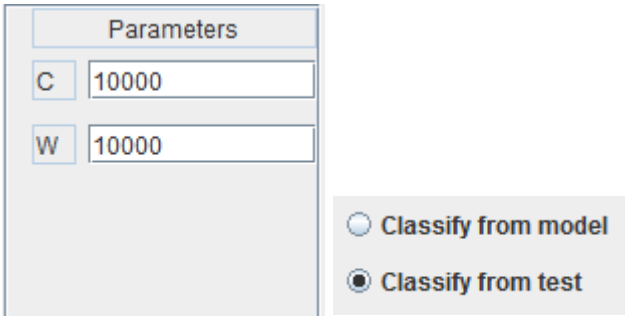
La clasificación se ha realizado con los siguientes parámetros:

- $C=10000$
- $W=10000$
- Kernel : Linear

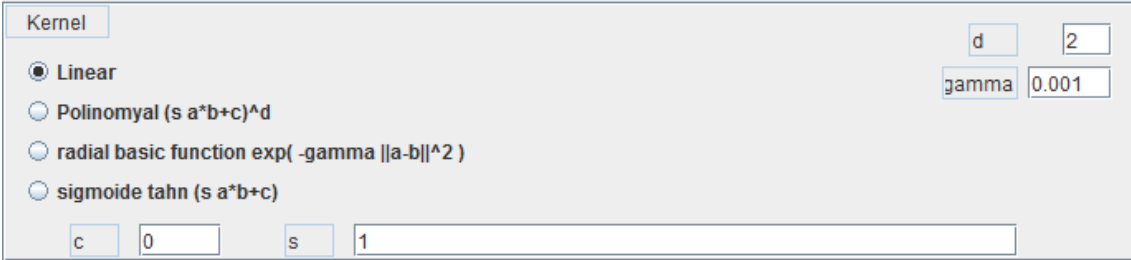
### 7.2.1 File to Model.

Lo primero que debemos hacer es pulsar el botón:  para cargar un archivo creado anteriormente por el programa anteriormente descrito.

Antes de cargar el archivo deberemos configurar los parámetros del **Kernel** para su posterior análisis y el tipo de análisis deseado:

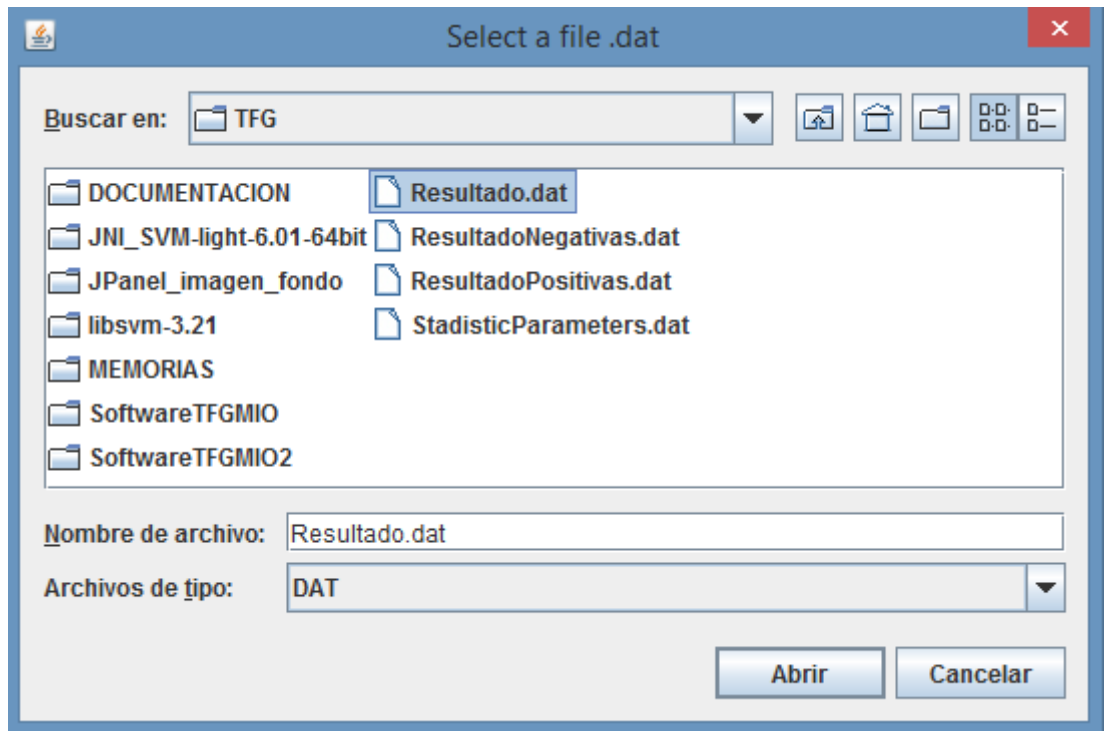


The 'Parameters' window contains two input fields: 'C' with the value '10000' and 'W' with the value '10000'. To the right of these fields are two radio button options: 'Classify from model' (unselected) and 'Classify from test' (selected).



The 'Kernel' window shows four radio button options: 'Linear' (selected), 'Polinomyal (s a\*b+c)^d', 'radial basic function exp( -gamma ||a-b||^2 )', and 'sigmoide tahn (s a\*b+c)'. On the right, there are input fields for 'd' (value 2) and 'gamma' (value 0.001). At the bottom, there are input fields for 'c' (value 0) and 's' (value 1).

Una vez configurado a nuestro gusto los parámetros procederemos a pulsar “File to Model”, y seleccionaremos el archivo “Resultado.dat”:



que es de donde el programa filtrará los datos. Si la carga ha ido bien, nos mostrará en el “log” el siguiente mensaje:

```
Archivo cargado con éxito
```

### 7.2.2 Model.

Antes de Aprender o clasificar, existe la opción de cargar un modelo ya creado anteriormente.

Model

En este caso cogerá automáticamente el archivo “modeloJava.dat” ubicado en la raíz del directorio y aparecerá el siguiente mensaje de

confirmación: Loading Model ..

### 7.2.3 Learning.

Por el contrario si queremos que cree un modelo nuevo a partir del archivo “Resultados.dat” cargado anteriormente en el paso uno (**File to**

**Model**), pulsaremos el botón:

Learning

```
TRAINING SVM-light MODEL ..
DONE.
```

será la siguiente: . Con una salida por log de eclipse y consultable en los archivos de referencia de Java de:

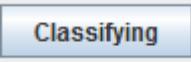
```

--- Native C function: scanning examples, now .. (JNI Interface)
0..20..40..60..80..100..120..140..160..175
OK. (176 examples read)
--- Native C function: documents allocated successfully.|
--- Native C function: engaging the training process.
Setting default regularization parameter C=962.2342
Optimizing.....done. (14 iterations)
Optimization finished (1 misclassified, maxdiff=0.00093).
Runtime in cpu-seconds: 0.06
Number of SV: 42 (including 29 at upper bound)
L1 loss: loss=11.06163
Norm of weight vector: |w|=144.28745
Norm of longest example vector: |x|=0.20412
Estimated VCdim of classifier: VCdim<=868.45307
Computing XiAlpha-estimates...done
Runtime for XiAlpha-estimates in cpu-seconds: 0.00
XiAlpha-estimate of the error: error<=22.16% (rho=1.00,depth=0)
XiAlpha-estimate of the recall: recall=>77.27% (rho=1.00,depth=0)
XiAlpha-estimate of the precision: precision=>78.16% (rho=1.00,depth=0)
Number of kernel evaluations: 2601
--- Native C function: training has been done.
--- Native C function: creating Java return type.
--- Native C function: classifier model created successfully.
--- Native C function: creating Java object has been done.

```

#### 7.2.4 Classify.

Por último, pasaremos a clasificar los datos introducidos anteriormente

mediante el botón: . Donde en este ejemplo la salida tras la clasificación ha sido la siguiente:

```
0.9943181818181818 PRECISION=RECALL USING THE JAVA OBJECT.
```

Se entiende que el resultado de la operación está dividido entre 100.

**NOTA IMPORTANTE: (ES POSIBLE QUE AL EJECUTAR EL PROGRAMA SVM NOS SALTE UNA EXCEPCION POR FALTA DE LA LIBRERÍA svmlight-64. PARA SOLUCIONARLO, COPIAR EL ARCHIVO svmlight-64.dll EN C:/Windows/System32)**

### 7.3 FUTUROS DESARROLLOS

- Complimentar salida del log de la ventana gráfica de SVM.
- Incorporación de filtrado de imágenes con el fin de homogeneizarlas y realizar una clasificación más especializada.

- Habilitar un botón “reset” para no tener que cerrar y abrir el programa cada vez que se carga una imagen nueva.
- Introducir otra ventana gráfica para clasificación por histogramas y así hacer la comparativa con el que ya está desarrollado.
- Hacer personalizable el tamaño del cuadrado a la hora de elegir una muestra positiva o negativa en la ventana de análisis de texturas.
- Creación de ventana con información de los resultados estadísticos sacados en cada iteración del análisis textural.
- Clasificación sin necesidad de muestreo del usuario.